

Leandro Bueno

**Interface Cérebro-Computador Baseada em
EEG Utilizando Redes Neurais
Auto-Organizadas**

Vitória – ES

2017

Leandro Bueno

Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Doutor em Engenharia Elétrica.

Universidade Federal do Espírito Santo – UFES

Departamento de Engenharia Elétrica

Programa de Pós-Graduação em Engenharia Elétrica – PPGEE

Orientador: Teodiano Freire Bastos Filho

Coorientador: André Ferreira

Vitória – ES

2017

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial Tecnológica,
Universidade Federal do Espírito Santo, ES, Brasil)

B928i Bueno, Leandro, 1977-
Interface cérebro-computador baseada em EEG utilizando
redes neurais auto-organizadas / Leandro Bueno. – 2017.
144 f. : il.

Orientador: Teodiano Freire Bastos Filho.

Coorientador: André Ferreira.

Tese (Doutorado em Engenharia Elétrica) – Universidade
Federal do Espírito Santo, Centro Tecnológico.

1. Interface cérebro-computador. 2. Eletroencefalografia.
3. Redes neurais (Computação). 4. Mapas auto-organizáveis.
I. Bastos Filho, Teodiano Freire. II. Ferreira, André. III.
Universidade Federal do Espírito Santo. Centro Tecnológico. IV.
Título.

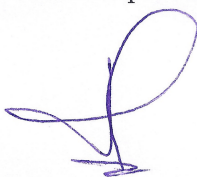
CDU: 621.3

Leandro Bueno

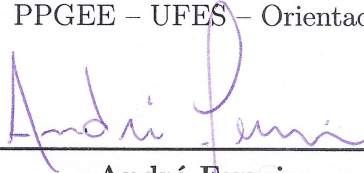
Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Doutor em Engenharia Elétrica.

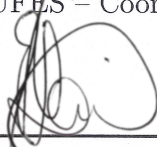
Trabalho aprovado. Vitória, ES, 06 de junho de 2017.



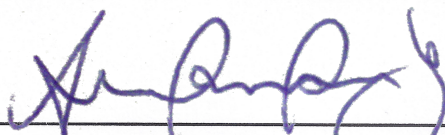
Teodiano Freire Bastos Filho
PPGEE – UFES – Orientador



André Ferreira
PPGEE – UFES – Coorientador



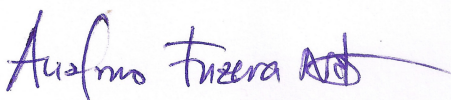
Eduardo Rocon de Lima
CAR/CSIC - Espanha – Examinador Externo



Alessandro Botti Benevides
UNIPAMPA – Examinador Externo



Jorge Leonid Aching Samatelo
DEL – UFES – Examinador Externo



Anselmo Frizera Neto
PPGEE – UFES – Examinador Interno

Vitória, ES

2017

Este trabalho é dedicado às pessoas que me ajudaram e incentivaram.

Agradecimentos

Gostaria de agradecer a todos os que me ajudaram neste trabalho, com recursos e com apoio:

Ao professor Teodiano por me apoiar na execução deste trabalho desde o seu início, alguns anos atrás, e até hoje;

Ao professor André pela coorientação deste trabalho;

Ao PPGE–UFES pela oportunidade e pela cessão do espaço e equipamentos durante a realização deste trabalho;

A Lucélia, por me aguentar e incentivar durante todos estes anos de trabalho, primeiro à distância e depois bem de perto;

Aos meus pais pela educação que me deram.

*Tudo deveria se tornar o mais simples possível,
mas não simplificado.
(Albert Einstein)*

Resumo

Nesta Tese de Doutorado se apresenta o desenvolvimento de um sistema de Interface Cérebro Computador (ICC) que utiliza sinais de Eletroencefalografia (EEG) e classificadores baseados em redes neurais auto-organizadas (Self Organizing Maps – SOM). Nesta Tese se analisam os problemas das ICCs e se apresentam os resultados conseguidos com o sistema desenvolvido. Este sistema utiliza um equipamento clínico de aquisição de sinais EEG e um computador pessoal para processar os dados. Usando a energia das componentes de frequência dos sinais EEG capturados como características, e um classificador baseado em uma rede neural auto-organizada. O grande desafio da utilização das redes auto-organizadas é a interpretação da saída da rede, devido a que esta rede possui uma saída para cada um dos neurônios presentes na rede. A contribuição desta tese está no método de interpretação da saída dos neurônios da rede SOM, o qual é implementado através de um conjunto de máscaras que representam a probabilidade da ativação dos mesmos para uma determinada classe. Todos os algoritmos utilizados nesta Tese de Doutorado podem ser adaptados facilmente para serem executados em sistemas embarcados com menor poder de processamento, tais como Processadores Digitais de Sinais (Digital Signal Processor – DSP) ou microcontroladores. A interface cérebro-computador (ICC) desenvolvida nesta Tese de Doutorado foi testada e validada de forma *off-line*, com dados de bancos de dados externos de EEG, e com voluntários, apresentando resultados satisfatórios em ambos os casos, quando comparados a outros trabalhos da literatura com o mesmo número de tarefas.

Palavras-chaves: Interface Cérebro-Computador. Redes Neurais Auto-Organizadas. EEG.

Abstract

This Doctoral Thesis presents the development of a Brain Computer Interface (BCI) system using Electroencephalography (EEG) signals and Self Organizing Maps (SOM) artificial neural networks as classifier. In this Thesis the problems of a BCI are analyzed and the classification results of the system is presented. This system uses a clinic acquisition equipment for EEG signal acquisition and a personal computer to process the data, using the energy of the frequency components of the EEG signal as characteristics and a classifier based on a Self Organizing Map as classifier. The great challenge in using SOM as a classifier is the interpretation of the outputs of the map, as it has as many outputs as it has neurons in the map. The contribution of this Thesis is in the interpretation method of the outputs of the map, which is done by means of the use of a set of masks that represents the probability of the activation of a neuron in the map representing a specific class. The algorithms used on this Doctoral Thesis can be easily adapted to be executed in embedded systems with less processing power, like Digital Signal Processors (DSP) or microcontrollers. The Brain Computer Interface developed in this Doctoral Thesis was tested and validated off-line, with an external database, and with data from volunteers, presenting satisfactory results in both cases, according to similar results from the literature.

Key-words: Brain-Computer Interface. Self-Organizing Maps. EEG.

Lista de ilustrações

Figura 1 – Representação da estrutura de um neurônio do sistema nervoso periférico (Adaptada de Malmivuo (MALMIVUO; PLONSEY, 1995)).	29
Figura 2 – Campo elétrico gerado pela excitação das membranas de um neurônio piramidal do córtex cerebral. As linhas descontínuas representam as superfícies isopotenciais, e as linhas contínuas, os fluxos das correntes. As superfícies isopotenciais se distribuem dentro do volume e representam os pontos do espaço onde o potencial gerado pelo dipolo do neurônio possui o mesmo valor. Figura retirada de (GLOOR, 1985).	30
Figura 3 – Campo elétrico gerado pela excitação de um tecido formado por um número de neurônios piramidais do córtex cerebral. As linhas representam as superfícies isopotenciais geradas pelo tecido. Os ângulos apresentados na figura representam, de maneira bidimensional, os ângulos sólidos que geram os potenciais dos eletrodos. Figura retirada de (GLOOR, 1985).	31
Figura 4 – Campo elétrico gerado pela excitação de um tecido nervoso e os potenciais na fronteira do meio onde este tecido está localizado. Figura retirada de (GLOOR, 1985).	32
Figura 5 – Área coberta por um determinado tipo de eletrodo utilizado para a captura de dados utilizados em ICCs. EEG: Eletrodo posicionado sobre a pele (couro cabeludo); ECoG: Eletrodo posicionado sobre as meninges; <i>Local F.P</i> : eletrodo posicionado sob as meninges; <i>Single Unit A.P</i> : eletrodo posicionado sobre um único neurônio. Figura retirada de (SCHWARTZ et al., 2006).	33
Figura 6 – Conexões entre os neurônios e o córtex cerebral através da medula. Figura adaptada de Gray (GRAY, 1918).	34
Figura 7 – Homúnculo representando a posição no córtex cerebral das distintas funções sensoriais ou motoras. Figura adaptada de (PENFIELD; RASMUSSEN, 1950).	35
Figura 8 – Posicionamento dos eletrodos de acordo com o sistema internacional 10/20 (Adaptada de Malmivuo, (MALMIVUO; PLONSEY, 1995)). Em A, vista lateral, e em B, vista superior. As regiões correspondem a Pg: Nasofaringeal; A: Auricular; Fp: Frontal Polar; F: Frontal; C: Central; T: Temporal; P: Parietal; O: Occipital.	35
Figura 9 – Esquema simplificado de uma ICC utilizado como base para o desenvolvimento do trabalho. Figura do autor.	41

Figura 10	–Esquema simplificado da estrutura de um amplificador de sinais EEG que cumpre com as necessidades de isolamento do sujeito de forma a garantir a segurança do mesmo contra choques elétricos. Figura do autor.	42
Figura 11	–Exemplos de aplicação de filtros de Laplace em imagens representando os potenciais de sinais de EEG. Representação dos potenciais originais, em (a). Em (b) e em (c) estão representados os resultados da aplicação dos respectivos filtros de Laplace. Figuras do autor.	46
Figura 12	–Exemplos de aplicação de filtros Laplace em séries temporais que representam os potenciais dos sinais EEG. Representação dos potenciais originais, em (a). Em (b) está representado o resultado da aplicação do filtro de Laplace. Figuras do autor.	47
Figura 13	–Disposição dos eletrodos utilizados para a aquisição dos sinais representados nas Figuras 12 e 11. Figura adaptada de (MALMIVUO; PLONSEY, 1995).	47
Figura 14	–Aplicação do algoritmo PCA como filtro para remoção de artefatos dos sinais EEG. Figuras do autor.	50
Figura 15	–Em (a) Representação do cérebro humano indicando as regiões mais importantes. Em (b) Representação do cérebro humano indicando as regiões mais importantes com mais detalhe. Ambas as figuras foram adaptadas da versão digital do livro <i>Gray's anatomy</i> , 1918 (GRAY, 1918) disponível <i>on-line</i> e de domínio público.	54
Figura 16	–Representação de um modelo oculto de Markov (HMM). Os estados representados não são visíveis ao observador. As observações permitem a inferência dos estados, conhecidas as probabilidades representadas na figura. Figura do autor.	57
Figura 17	–Representação da estrutura de um neurônio artificial. Figura do autor.	59
Figura 18	–Evolução do treinamento de uma rede SOM para uma série de dados aleatórios gerados para exemplificar o funcionamento da rede. Pode-se observar que a rede aproxima a distribuição dos dados utilizados para o treinamento. Figuras do autor.	61
Figura 19	–Esquema representativo do diagrama de tempos para o protocolo de experimentos da Universidade Técnica de Graz (Graz BCI). Figura do autor.	67
Figura 20	–Estrutura da tarefa implementada para o sistema de aquisição. Figura do autor.	69

Figura 21	– Representação das características de frequência dos sinais EEG de um voluntário na tarefa de inatividade para os canais utilizados no sistema. No eixo horizontal está representado o tempo entre o segundo 1 e o segundo 4 de uma repetição, representando a tarefa de inatividade. No eixo vertical estão representadas amplitudes das componentes de frequência entre 7 e 31 Hz. A cor azul indica menor amplitude da componente, e a cor vermelha indica maior amplitude da componente. Figuras do autor.	72
Figura 22	– Representação da atividade dos sinais EEG na tarefa de imaginação de movimentos. O <i>central sulcus</i> corresponde ao eixo horizontal no centro da figura. Dados extraídos de um dos experimentos com sujeitos voluntários. A cor azul indica menor amplitude da componente, e a cor vermelha indica maior amplitude da componente. Figura do autor. . .	73
Figura 23	– Equipamento BrainNet BNT36, utilizado nos experimentos no NTA/UFES. Figura retirada da internet(http://www.lynxtec.com.br/medica.htm). . .	75
Figura 24	– Gorro com eletrodos segundo o sistema 10/20 utilizado nos experimentos de aquisição de EEG. Figura do autor.	77
Figura 25	– Diagrama de blocos do algoritmo de validação de dados utilizando as componentes de frequência. Figura do autor.	85
Figura 26	– Representação dos dados de correlação resultantes da validação dos dados experimentais. (a) Dados inaceitáveis: observa-se uma correlação baixa (ao redor de 0,5) e não se observam mudanças durante a execução da tarefa. (b) Dados aceitáveis: observa-se uma correlação alta (ao redor de 0,75) nas tarefas inicial e de imaginação de movimento; a apresentação e retirada do estímulo geram grandes mudanças nas características, resultando em uma baixa correlação. Figura do autor. .	86
Figura 27	– Saída do classificador para os dados de verificação do voluntário 1. Valor esperado no traço em (a), e saída do classificador marcada com ‘*’ em (b). Figura do autor.	92
Figura 28	– Máscaras relacionadas ao voluntário 1. Em <i>a</i> estão representadas as máscaras de classificação utilizadas, e em <i>b</i> uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.	92
Figura 29	– Saída do classificador para os dados de verificação do voluntário 2. Valor esperado no traço em (a), e saída do classificador marcada com ‘*’ em (b). Figura do autor.	93

Figura 30	– Máscaras relacionadas ao voluntário 2. Em <i>a</i> estão representadas as máscaras de classificação utilizadas, e em <i>b</i> uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.	94
Figura 31	– Saída do classificador para os dados de verificação do voluntário 3. Valor esperado no traço em (a), e saída do classificador marcada com ‘*’ em (b). Figuras do autor.	94
Figura 32	– Máscaras relacionadas ao voluntário 3. Em <i>a</i> estão representadas as máscaras de classificação utilizadas, e em <i>b</i> uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.	95
Figura 33	– Saída do classificador para os dados de verificação do voluntário A. Valor esperado no traço, e saída do classificador marcada com ‘*’. Figura do autor.	96
Figura 34	– Máscaras relacionadas ao voluntário A. Em <i>a</i> estão representadas as máscaras de classificação utilizadas, e em <i>b</i> uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.	97
Figura 35	– Saída do classificador para os dados de verificação do voluntário H. Valor esperado no traço, e saída do classificador marcada com ‘*’. Figura do autor.	98
Figura 36	– Máscaras relacionadas ao voluntário H. Em <i>a</i> estão representadas as máscaras de classificação utilizadas, e em <i>b</i> uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.	99
Figura 37	– Saída do classificador para os dados de verificação do voluntário V. Valor esperado no traço, e saída do classificador marcada com ‘*’. Figura do autor.	100
Figura 38	– Máscaras relacionadas ao voluntário V. Em <i>a</i> estão representadas as máscaras de classificação utilizadas, e em <i>b</i> uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.	100
Figura 39	– Esquema das placas do sistema de aquisição, processamento e comunicação utilizadas pelo sistema. Também se observa na figura a distribuição das fontes de alimentação utilizadas por cada uma das etapas. .	129
Figura 40	– Diagrama de blocos da placa de amplificação. Este diagrama representa os blocos funcionais da placa de amplificação. As placas individuais de amplificação conectam-se às entradas e saídas através de uma placa base que também provê alimentação a estas.	134

Figura 41	–Diagrama esquemático da placa base do sistema de amplificação. Pode-se observar as conexões dos 8 eletrodos de entrada, as conexões de saída e a fonte de alimentação regulada que compõem o circuito desta placa.	134
Figura 42	–Fotografia da placa base do sistema de amplificação onde se pode observar a fonte de alimentação, e os conectores de entrada e saída das placas de amplificação de 2 canais.	135
Figura 43	–Diagrama esquemático da placa de amplificação de 2 canais utilizada no dispositivo. O circuito possui uma entrada diferencial seguida por um conjunto de filtros passa-baixas, passa-altas, ambos com ganhos não-unitários, um filtro “notch” para atenuar os efeitos do ruído induzido pela rede, e um amplificador para ajuste de ganho do dispositivo.	136
Figura 44	–Fotografia da placa de amplificação de 2 canais utilizada no dispositivo portátil.	136
Figura 45	–Fotografia das placas de amplificação montadas na placa base. Nesta foto pode-se observar o encaixe das placas individuais à placa base e os conectores para ajuste de ganho das placas de amplificação.	137
Figura 46	–Diagrama esquemático da placa de processamento dos sinais EEG. Esta placa está baseada no dsPIC33FJ256GP710 do fabricante Microchip.	138
Figura 47	–Fotografia da placa de processamento dos sinais EEG.	139
Figura 48	–Fotografia do protótipo da placa de comunicação. A placa possui conectividade USB e Bluetooth® , e a capacidade de armazenar dados em uma placa de memória Secure Digital™ (SD™)	141
Figura 49	–Diagrama esquemático da placa de comunicação.	142
Figura 50	–Fotografia das placas de processamento e comunicação conectadas. Este conjunto realiza a aquisição, processamento, armazenamento e envio dos sinais EEG.	143

Lista de tabelas

Tabela 1	– Demonstrativo dos resultados dos testes realizados com dados do BCI Competition.	91
Tabela 2	– Matriz de confusão para o voluntário 1 utilizando a rede com 25 neurônios (matriz quadrada, 5×5) e 40 características, treinados com 100 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras.	91
Tabela 3	– Matriz de confusão para o voluntário 2 utilizando a rede com 25 neurônios (matriz quadrada, 5×5) e 40 características, treinados com 100 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras.	93
Tabela 4	– Matriz de confusão para o voluntário 3 utilizando a rede com 25 neurônios (matriz quadrada, 5×5) e 40 características, treinados com 100 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de movimento da Mão Direita – IMD, Imaginação de movimento da Mão Esquerda – IME, e recordar Palavras.	95
Tabela 5	– Demonstrativo dos resultados dos experimentos realizados no laboratório.	96
Tabela 6	– Matriz de confusão para o voluntário A utilizando a rede com 36 neurônios (matriz quadrada, 6×6) e 38 características, treinados com 500 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras. A segunda metade da tabela apresenta resultados após a reclassificação das saídas.	97
Tabela 7	– Matriz de confusão para o voluntário H utilizando a rede com 36 neurônios (matriz quadrada, 6×6) e 60 características, treinados com 200 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras. A segunda metade da tabela apresenta resultados após a reclassificação das saídas.	98

Tabela 8	– Matriz de confusão para o voluntário V utilizando a rede com 36 neurônios (matriz quadrada, 6×6) e 60 características, treinados com 200 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras. A segunda metade da tabela apresenta resultados após a reclassificação das saídas.	99
Tabela 9	– Classificação dos dispositivos de acordo com a proteção do usuário contra riscos de choque elétrico. Os dispositivos de classe I são os que requerem os níveis mais baixos de isolamento. Os dispositivos de classe III apresentam isolamento reforçado e utilizam tensões de alimentação reduzida.	131
Tabela 10	– Classificação de segurança dos dispositivos de aplicação clínica (PRUTCHI; NORRIS, 2005). Segundo esta classificação, o dispositivo aqui descrito deve ser caracterizado com “BF”.	131
Tabela 11	– Valores de sensibilidade de entrada para os ganhos do MultiAmp e do dispositivo desenvolvido. Considera-se para o cálculo da sensibilidade a placa de aquisição utilizada no laboratório (NI PCI-6024E, 12 bits) e o conversor A/D disponível no DSPic utilizado no dispositivo, também de 12 bits, e a excursão máxima da saída de cada um dos amplificadores utilizados.	133

Lista de abreviaturas e siglas

AAR	<i>Adaptive Autoregressive</i> – Modelo Autorregressivo Adaptativo;
AVC	Acidente Vascular Cerebral;
BCI	<i>Brain–Computer Interface</i> ;
BMI	<i>Brain–Machine Interface</i> ;
CAR	Centro de Automática y Robótica;
CSIC	Consejo Superior de Investigaciones Científicas;
CSP	<i>Common Spatial Patterns</i> – Padrões Espaciais Comuns;
DSP	<i>Digital Signal Processor</i> – Processador Digital de Sinais;
ECoG	Eletrocorticografia;
EEG	Eletroencefalografia;
ELA	Esclerose Lateral Amiotrófica;
EMG	Eletromiografia;
ERD	<i>Event Related Desynchronization</i> – Dessincronização Relacionada a Eventos;
ERS	<i>Event Related Synchronization</i> – Sincronização Relacionada a Eventos;
FIR	<i>Finite Impulse Response</i> – Filtros com Resposta Temporal Finita ao Impulso;
fMRI	<i>Functional Magnetic Resonance Imaging</i> – Ressonância Magnética Funcional;
HMM	<i>Hidden Markov Models</i> – Modelos Ocultos de Markov;
ICA	<i>Independent Component Analysis</i> – Análise de Componentes Independentes;
ICC	Interface Cérebro–Computador;
IIR	<i>Infinite Impulse Response</i> – Filtros com Resposta Temporal Infinita ao Impulso;

LIS	<i>Locked – In Syndrome;</i>
LVQ	<i>Learning Vector Quantization;</i>
MIPS	<i>Million Instructions per Second</i> – Milhões de Instruções por Segundo;
MLP	<i>Multi Layer Perceptron</i> – Perceptron Multi Camada;
OMS	Organização Mundial da Saúde;
P300	Potencial positivo que ocorre aproximadamente 300ms após a apresentação de um estímulo esperado;
PCA	<i>Principal Component Analysis</i> – Analise de Componentes Principais
PET	<i>Positron Emission Tomography</i> – Tomografia por Emissão de Pósitrons;
RNA	Rede Neural Artificial;
SOM	<i>Self-Organizing Maps</i> – Mapas Auto Organizados;
SPS	<i>Samples per Second</i> – Amostras por Segundo;
SSVEP	<i>Steady State Visual Evoked Potential</i> – Potenciais Evocados Visuais de Estado Estacionário;

Lista de símbolos

α	Letra grega Alfa – Representa uma banda de frequência do sinal EEG compreendida entre 8Hz e 13Hz;
β	Letra grega Beta – Representa uma banda de frequência do sinal EEG compreendida entre 13Hz e 30Hz;
γ	Letra grega Gama – Representa uma banda de frequência do sinal EEG compreendida entre 30Hz e 50Hz;
δ	Letra grega Delta – Representa uma banda de frequência do sinal EEG compreendida entre 0,5Hz e 4Hz;
θ	Letra grega Theta – Representa uma banda de frequência do sinal EEG compreendida entre 4Hz e 8Hz;
μ	Letra grega Mi – Representa um ritmo presente no sinal EEG com frequência dominante ao redor de 13Hz, localizada na região sensorimotora do cérebro.

Sumário

1	Introdução	22
1.1	Motivação	22
1.2	Objetivos	23
1.3	Estrutura da Tese	24
2	Revisão teórica e estado da arte	26
2.1	Introdução às características fisiológicas dos sinais EEG	26
2.1.1	Modelagem de tecidos biológicos	27
2.1.2	Modelagem dos neurônios	28
2.1.3	A formação do sinal EEG	30
2.1.4	A organização somatotópica do cérebro	33
2.2	Tipos de ICCs	36
2.3	Características do sinal EEG utilizadas em ICC	37
2.3.1	Potenciais Característicos	37
2.3.2	Frequências características	39
2.4	Sistemas de aquisição e processamento de sinais EEG	40
2.4.1	Arquitetura interna dos amplificadores empregados na captura de EEG	41
2.4.2	Aquisição dos sinais	43
2.4.3	Processamento e interpretação de sinais de EEG	44
2.5	Análise das tecnologias atuais	44
2.5.1	Algoritmos de pré-processamento	44
2.5.1.1	Filtragem temporal e espacial	45
2.5.1.2	Análise de componentes principais – PCA	48
2.5.1.3	Análise de componentes Independentes – ICA	51
2.5.2	Extração de características	53
2.5.3	Algoritmos de classificação	56
2.5.3.1	Modelos ocultos de Markov	56
2.5.3.2	Redes neurais artificiais	58
2.5.3.3	Métodos estatísticos aplicados às características dos sinais	62
2.5.4	Trabalhos de referência de grupos da área de ICCs	63
2.6	Discussão do Capítulo	64
3	Desenvolvimento de um sistema de aquisição de sinais EEG	66
3.1	Análise dos experimentos da literatura e desenvolvimento de um modelo experimental	66

3.1.1	Graz BCI	66
3.1.2	Berlin BCI	67
3.1.3	O paradigma de Potenciais Evocados Visuais de Regime Permanente (SSVEP)	68
3.1.4	O paradigma P300	68
3.1.5	O paradigma assíncrono	68
3.1.6	Procedimentos adotados para as tarefas inicialmente realizadas . . .	69
3.2	Proposta conceitual de requisitos de um sistema de captura de sinais EEG	70
3.2.1	Justificativa fisiológica dos experimentos	70
3.2.2	Requisitos de qualidade do sinal	74
3.2.2.1	Equipamento de aquisição de EEG	74
3.3	Sistema final desenvolvido	75
3.4	Discussão do capítulo	78
4	Discussão sobre algoritmos de processamento, extração de características e classificação	79
4.1	Algoritmos de pré-processamento	79
4.2	Algoritmos de extração de características	80
4.2.1	Análise de componentes de frequência	81
4.3	A rede neural SOM como classificador	82
4.3.1	Criação e interpretação das máscaras de classificação das saídas da rede SOM	83
4.4	Validação dos dados experimentais <i>on-line</i> utilizando as características de frequência dos sinais adquiridos	84
4.5	O sistema implementado	87
4.5.1	A implementação final	87
4.6	Discussão do capítulo	87
5	Resultados	89
5.1	Escolha dos voluntários para participação os experimentos	89
5.2	Escolha de parâmetros do classificador	89
5.3	Comparação dos resultados de classificação	90
5.3.1	Resultados utilizando bancos de dados	90
5.3.2	Resultados com dados dos voluntários do laboratório	96
5.4	Considerações sobre o resultados apresentados	101
6	Conclusões e trabalhos futuros	103
6.1	Contribuições	103
6.1.1	Processamento de sinais	103
6.1.1.1	Algoritmo de validação de sinais EEG	104

6.1.1.2	Seleção de características para o classificador	104
6.1.1.3	Desenvolvimento do classificador neural	104
6.1.2	Desenvolvimento de um sistema embarcado de processamento <i>on-line</i>	105
6.2	Publicações	106
6.3	Trabalhos futuros	107
Referências		109

Apêndices 125

APÊNDICE A Desenvolvimento de dispositivo portátil para a aquisição e processamento de sinais EEG 126

A.1	Desafios na implementação de um dispositivo embarcado para a captura e processamento de sinais EEG	126
A.1.1	Aspectos da etapa de amplificação	127
A.1.2	Aspectos informáticos	127
A.1.3	Visão geral do sistema desenvolvido	127
A.2	Diretrizes de segurança elétrica para dispositivos de amplificação de potenciais biológicos e características elétricas do dispositivo desenvolvido	128
A.3	Amplificação e filtragem dos sinais	132
A.4	Aquisição e processamento	136
A.4.1	Estimação do custo computacional do módulo de processamento de sinais EEG	138
A.5	Armazenamento e envio de dados	141
A.6	Resumo e conclusões	143

1 Introdução

Sistemas de ajuda a pessoas com deficiência têm atraído grande interesse da sociedade, visto que o número de pessoas que necessitam de algum tipo de ajuda técnica vem crescendo nos últimos anos, chegando a cerca de 1/7 da população mundial, como descrito no plano de ações globais 2014–2021 da Organização Mundial da Saúde – OMS (ORGANIZATION, 2015). Isto se deve, principalmente, aos avanços da medicina, que ampliam a sobrevida de pessoas que sofreram algum tipo de limitação motora decorrente de acidentes ou doenças degenerativas. Este aumento no número de pessoas que necessitam de algum tipo de ajuda torna o problema de sua inclusão, segundo a OMS, uma preocupação de muitos governos (Organización Mundial de la Salud, 2005). A OMS apresenta, ainda, em seu último relatório mundial sobre a deficiência, divulgado em 2011 (World Health Organization, 2011), uma série de sugestões de ações a serem implementadas para melhorar a vida das pessoas com deficiência, incluindo ações de pesquisa e desenvolvimento. Sendo que as ajudas técnicas podem ser de diversos tipos, desde as mais simples, como muletas e bengalas, até complexas Interfaces Cérebro–Computador (ICCs) baseadas na intenção de movimento, como a apresentada nesta Tese de Doutorado.

1.1 Motivação

Como já comentado anteriormente, o desenvolvimento de ajudas técnicas continua sendo bastante atual e motiva vários grupos de pesquisa em todo o mundo, além de instituições como a OMS.

Neste contexto, as ICCs são utilizadas com o intuito de recuperar, principalmente, a capacidade de comunicação de pessoas que perderam a capacidade de utilizar os meios naturais para comunicar-se, como é o caso de pacientes com Esclerose Lateral Amiotrófica (ELA) ou da Síndrome do Encarceramento (Locked-In Syndrome – LIS) (DORNHEGE, 2006). Pacientes destas patologias, em estados avançados, não possuem movimentos de seus membros, devido à degeneração dos tecidos, no caso de ELA, ou devido a uma lesão, no caso de LIS, embora o cérebro não tenha sido afetado e mantenha suas funções cognitivas inalteradas. Mais recentemente, as ICCs estão sendo utilizadas também como equipamentos de entretenimento por pessoas sem nenhum tipo de deficiência, embora os primeiros desenvolvimentos e a motivação deste trabalho não estejam focados no entretenimento (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

A motivação desta Tese de Doutorado reside no interesse de desenvolver uma Interface Cérebro–Computador que possa ser implementada como uma ajuda técnica prática, na forma de um dispositivo. Este dispositivo deve ser capaz de capturar os sinais EEG,

processá-los para a extração de características e ainda executar um algoritmo de classificação para identificar as intenções do usuário, gerando informação a respeito da atividade mental para que esta informação possa ser usada como sinal de controle.

Existem hoje na literatura diferentes técnicas de processamento de sinais EEG associados a diferentes técnicas de classificação que podem ser utilizadas para implementar a solução deste problema. Entretanto, muitas destas técnicas possuem aplicação limitada ou necessitam que o usuário do equipamento seja constantemente estimulado com luzes, por exemplo, como é o caso dos sistemas que utilizam Potenciais Evocados Visuais de Regime Permanente (*Steady-State Visual Evoked Potential – SSVEP*) (TELLO, 2016; FLORIANO, 2016; ATENCIO, 2015; COTRINA; CASTILLO; BASTOS FILHO, 2014). Outros sistemas são baseados em tabuleiros de escolhas, onde o usuário escolhe entre as distintas opções (CASTILLO, 2014; FERREIRA, 2008). Esta última opção também pode ser usada para implementar árvores de escolhas para digitação (OBERMAIER; MÜLLER; PFURTSCHELLER, 2003; OBERMAIER, 2001).

As técnicas de classificação como as desenvolvidas nesta Tese de Doutorado apresentam novas possibilidades de utilização para métodos até então utilizados apenas em outras aplicações. Estas novas técnicas de classificação visam a avançar no desenvolvimento de dispositivos baseados em EEG que possam ser aplicados, de forma embarcada, a diferentes situações e com diferentes usuários.

1.2 Objetivos

O objetivo desta Tese de Doutorado é o desenvolvimento de técnicas que possam ser aplicadas em sinais EEG com a finalidade de implementar uma ICC. A pesquisa também apresenta uma arquitetura básica de hardware capaz de implementar as técnicas apresentadas em um dispositivo portátil. O sistema desenvolvido neste trabalho utiliza um equipamento clínico para a aquisição dos sinais EEG e um computador pessoal, usando técnicas de processamento de sinais, extração de características e classificação que podem ser implementadas em equipamentos com capacidades limitadas de processamento, através de sistemas de captação e amplificação de sinais portáteis.

Desta forma, espera-se que o sistema possa ser implementado futuramente na forma de um equipamento autônomo, incorporando a aquisição de sinais ao processamento, permitindo o uso desta tecnologia por um maior número de pessoas. Os principais grupos de pessoas que poderiam se beneficiar deste tipo de desenvolvimento são as pessoas com ELA, também conhecida como doença de Lou Gehrig, LIS, entre outros com limitações severas.

Para alcançar este objetivo foi inicialmente realizado um estudo das técnicas de processamento de sinais e extração de características para identificar entre as técnicas

mais frequentes na literatura, quais seriam as mais adequadas a este trabalho, visando não somente a implementação inicial utilizando um PC como também direcionando o desenvolvimento para aplicações embarcadas.

Outro objetivo buscado foi a implementação de classificadores adequados a este trabalho, optando-se pelo desenvolvimento de uma nova arquitetura de classificadores utilizando técnicas de mapas auto-organizados, as quais são utilizadas em outras aplicações, mas não tão frequentemente em ICCs. Estas técnicas podem ser implementadas em sistemas embarcados baseados em DSP, devido à sua possibilidade de otimização, dependendo da arquitetura da rede.

1.3 Estrutura da Tese

Esta Tese de Doutorado está organizada em três partes, sendo a primeira dedicada à revisão do estado da arte, a segunda à apresentação do desenvolvimento do trabalho, e a terceira e última parte dedicada à apresentação das conclusões e propostas de trabalhos futuros.

A primeira parte é composta pelo Capítulo 2, o qual inicia-se com uma breve introdução à natureza do sinal de EEG e suas características fisiológicas que podem ser usadas para a identificação das intenções motoras de uma pessoa. Apresenta-se também os tipos básicos de ICCs e as características dos sinais mais comumente utilizadas na literatura. Ao final do Capítulo 2, apresenta-se uma discussão do estado da arte dos desenvolvimentos atuais na área de processamento e classificação destes sinais, com vista ao controle de dispositivos ou de interfaces de auxílio a pessoas com deficiência.

A segunda parte é composta pelos Capítulos 3 e 4. No Capítulo 3, são apresentados os procedimentos utilizados na literatura para a realização de experimentos. Também está apresentado neste Capítulo a justificativa fisiológica relacionada ao protocolo utilizado nos experimentos desta pesquisa, além dos requisitos de segurança que devem ser observados para a realização desses experimentos.

O Capítulo 4 apresenta os algoritmos utilizados nas implementações estudadas e sua relação com o trabalho implementado, além de apresentar o algoritmo de validação de dados *on-line* o qual é uma das contribuições deste trabalho.

A terceira parte é composta pelos Capítulos 5 e 6. O Capítulo 5 apresenta uma visão geral dos resultados obtidos com o sistema desenvolvido, utilizando uma base de dados de sinais EEG para a validação do algoritmo e comparação dos resultados com os de outros grupos de pesquisa, utilizando os mesmos dados. Neste capítulo também são apresentados os resultados observados com dados coletados de voluntários do laboratório, além dos critérios de seleção dos voluntários para o estudo.

O Capítulo 6 apresenta as conclusões e as propostas de trabalhos futuros e o Apêndice A complementa o Capítulo 6 apresentando o desenvolvimento preliminar de um sistema autônomo de captura e processamento de sinais com o objetivo de implementar uma ICC embarcada.

2 Revisão teórica e estado da arte

Neste Capítulo é apresentada uma revisão do estado da arte no âmbito das interfaces cérebro-computador, iniciando-se com uma introdução à estrutura cerebral e dos tecidos nervosos, além da apresentação de algumas das características dos sinais EEG, com um foco principal naquelas que podem ser utilizadas para a identificação e discriminação da atividade cerebral do usuário.

A seguir, são apresentadas diferentes classificações das ICCs, de acordo com suas características, e então se passa a uma descrição das características comumente encontradas na literatura. São também abordadas as estruturas de amplificação e captura dos sinais EEG encontradas na literatura e utilizadas neste trabalho.

Em seguida são discutidos alguns dos mais importantes algoritmos encontrados na literatura para pré-processamento, extração de características e classificação, justificando a utilização, ou não, nesta pesquisa, de cada um dos algoritmos apresentados.

Ao final do capítulo, apresentam-se alguns dados relativos a alguns dos grupos de pesquisa mais relevantes nesta área de desenvolvimento e as características dos desenvolvimentos de cada um deles.

2.1 Introdução às características fisiológicas dos sinais EEG

A denominação EEG é aplicada à atividade elétrica registrada sobre o couro cabeludo proveniente da atividade cerebral. Esta atividade foi descrita pela primeira vez por Hans Berger em 1929 (WOLPAW et al., 2000; MALMIVUO; PLONSEY, 1995). Esta atividade elétrica se caracteriza por representar um campo elétrico resultante da soma das contribuições dos campos elétricos de cada uma das células que compõem o tecido cerebral em uma determinada região.

As subseções seguintes apresentam uma breve descrição do processo de propagação dos sinais por um condutor volumétrico que pode ser utilizado como modelo para a propagação do sinal desde os neurônios até o exterior do couro cabeludo, além da descrição da estrutura dos neurônios cerebrais e do cérebro. Também se apresenta uma descrição das características do sinal relacionado à atividade cerebral.

O estudo da estrutura dos neurônios apresentados neste capítulo facilitará a compreensão das técnicas de processamento e classificação de dados bioinspiradas, como as redes neurais artificiais (RNA) utilizadas neste trabalho, para a classificação de sinais EEG.

2.1.1 Modelagem de tecidos biológicos

O corpo humano está formado por uma série de tecidos celulares que possuem uma grande quantidade de água em sua composição. Estas células utilizam uma variedade de íons para distintas funções dentro das células, o que confere ao tecido uma certa condutividade, especialmente os tecidos nervosos, musculares e sanguíneo. Por este motivo, os tecidos celulares podem ser modelados como condutores volumétricos, que são condutores com os seus parâmetros distribuídos através do volume. As características elétricas dos tecidos também são diferentes, de acordo com o tipo de tecido, já que cada tecido possui uma diferente concentração de eletrólitos e íons na sua composição.

As células de um organismo apresentam, em seu estado natural, uma diferença de potencial através de sua membrana. Esta diferença de potencial é gerada pela diferença entre as concentrações de íons entre o interior e o exterior da membrana da célula. Nas células nervosas, quando este potencial muda, pode-se dizer que a célula está sujeita a um estímulo, e este estímulo pode ser de dois tipos:

- Excitatório ou despolarizante, quando o potencial aumenta no interior da célula, mudando o seu potencial de repouso negativo a valores mais positivos.
- Inibitório ou hiperpolarizante, quando o potencial diminui no interior da célula, aumentando o potencial negativo da membrana, e dificultando a despolarização desta.

Para que uma célula nervosa, ou neurônio, despolarize-se e gere um impulso, é necessário que a energia dos estímulos recebidos seja suficientemente alta para superar um limite de despolarização individual da mesma. Quando uma célula nervosa está exposta a um estímulo despolarizante, que não seja suficientemente alto para que o potencial de membrana alcance o seu limite, a célula se comporta de maneira passiva, absorvendo os estímulos sem gerar nenhuma saída. Por outro lado, se estes estímulos recebidos forem suficientes para ultrapassar o limite próprio da célula, o neurônio se comporta de maneira ativa e gera um impulso característico, denominado impulso nervoso. Os estímulos inibitórios podem fazer com que seja necessário um aumento na quantidade ou na energia dos impulsos excitatórios para que um impulso nervoso possa ser gerado. Na seção 2.1.2 o modelo do neurônio será tratado com mais detalhe.

Por este comportamento das membranas dos neurônios, e pelas características condutivas dos tecidos, os órgãos do corpo humano podem ser modelados como condutores volumétricos, com uma série de dipolos elétricos atuando como fontes dentro deste condutor volumétrico. Nesta modelagem, os dipolos representam os neurônios, no caso do cérebro, e as terminações nervosas, no caso de órgãos musculares como o coração. Tecidos que não possuem membranas excitáveis podem ser considerados como condutores

volumétricos sem dipolos no seu interior, uma vez que as células são formadas por uma solução salina. Generalizando, pode-se considerar todo o corpo humano com um condutor volumétrico, com uma certa quantidade de dipolos fonte em seu interior, sendo que estas fontes são formadas pelos dipolos das membranas excitáveis das células nervosas.

Na literatura encontram-se diferentes modelos do corpo humano baseados em condutores volumétricos, sendo que muitos destes modelos foram elaborados para o estudo dos potenciais gerados pelo funcionamento do coração (MALMIVUO; PLONSEY, 1995) e são usados para modelar o funcionamento deste órgão. No caso do cérebro, estes modelos recebem muitas simplificações, quando comparados aos modelos utilizados para análise de dados cardíacos. No caso cardíaco, o dipolo formado pela atividade cardíaca está em uma posição aproximadamente fixa dentro do volume do condutor. No caso do cérebro, a atividade não pode ser completamente modelada por um número determinado de dipolos. A estrutura do condutor também apresenta dificuldades, já que entre o dipolo de interesse e os eletrodos usados para capturar o sinal existem camadas fechadas com diferentes características elétricas e com formas e espessuras que podem variar entre diferentes pessoas.

Os modelos simplificados utilizam esferas concêntricas com diferentes características elétricas correspondentes aos diferentes tecidos para modelar a cabeça. Modelos mais realistas também podem ser gerados, utilizando-se técnicas 3D e localizando-se os dipolos através de métodos numéricos. Neste contexto, Lemieux (LEMIEUX; MCBRIDE; HAND, 1996) apresenta um modelo gerado a partir de imagens de ressonância magnética, utilizando um método numérico para a resolução do problema direto, ou seja, para a determinação dos potenciais a partir de um número de fontes, sendo apresentados os métodos de cálculo e os resultados da comparação entre este método e o modelo analítico de esferas concêntricas. Entretanto, pela complexidade do modelo realista, a estimação de fontes utilizando os métodos descritos são inviáveis quando a aplicação é o controle de sistemas de ajuda a pessoas com deficiência, como é o caso desta Tese de Doutorado.

2.1.2 Modelagem dos neurônios

Os neurônios são células especializadas que formam o tecido nervoso, sendo de diferentes tipos: os especializados no transporte de informação entre o sistema nervoso central e os receptores nos tecidos; os especializados no processamento da informação, localizados no sistema nervoso central; e também os tipos responsáveis por fazer a interface com os músculos e com os diferentes receptores responsáveis pelos sentidos. Em geral, os neurônios possuem uma estrutura bastante peculiar que lhes permite concentrar os impulsos originados de diferentes fontes, gerando uma nova informação a partir da integração dos sinais recebidos.

Os neurônios possuem estruturas denominadas *dendritos* que permitem receber os

impulsos nervosos de outras células. Apresentam também uma prolongação, denominada *axônio*, a qual é responsável por levar o impulso nervoso resultante de sua atividade a outras células do corpo. A Figura 1 apresenta a estrutura de um neurônio com a maioria das suas estruturas internas.




Figura 1 – Representação da estrutura de um neurônio do sistema nervoso periférico (Adaptada de Malmivuo (MALMIVUO; PLONSEY, 1995)).

Cada neurônio gera uma saída de acordo com a integração dos impulsos recebidos nos seus dendritos. Se este resultado supera o potencial de limite necessário para despolarizar a membrana, o neurônio gera um impulso nervoso no seu axônio; caso contrário, nenhum impulso é gerado. O limite para a geração do impulso é uma característica individual de cada célula.

A conexão entre os distintos neurônios é denominada sinapse. A mais comum das sinapses é do tipo químico, na qual há uma separação física entre os neurônios. Quando um impulso elétrico chega à sinapse, substâncias químicas são liberadas e excitam o neurônio seguinte. Estas substâncias são chamadas neurotransmissores.

As sinapses elétricas não utilizam neurotransmissores, e os íons se transferem de uma célula diretamente à outra. Este tipo de conexão é mais rápida que a transmissão por neurotransmissores, mas não é comum nos tecidos do sistema nervoso central. Por outro

lado, são muito comuns em células como as da pele, e nos músculos. A propagação desta atividade elétrica através dos tecidos pode ser observada nos sinais mioelétricos (EMG), para o caso da propagação através das células musculares.

2.1.3 A formação do sinal EEG

Em estudos realizados por Gloor (GLOOR, 1985), é feita uma análise da formação do sinal EEG na qual, tomando por base a teoria dos condutores volumétricos, conclui-se que os sinais EEG são formados pelos potenciais das sinapses do tecido nervoso localizado dentro de um ângulo sólido abaixo do eletrodo. Este efeito ocorre devido a que o eletrodo captura a atividade dos neurônios sob sua região de influência, a qual apresenta uma característica cônica com o vértice localizado no eletrodo. Cada tipo de eletrodo apresenta um determinado ângulo, sendo que a localização do eletrodo no tecido gera o potencial capturado por este. A Figura 2 representa os potenciais teóricos ao redor de um neurônio e as curvas de corrente em um condutor volumétrico, para cada uma das curvas de potencial.




Figura 2 – Campo elétrico gerado pela excitação das membranas de um neurônio piramidal do córtex cerebral. As linhas descontínuas representam as superfícies isopotenciais, e as linhas contínuas, os fluxos das correntes. As superfícies isopotenciais se distribuem dentro do volume e representam os pontos do espaço onde o potencial gerado pelo dipolo do neurônio possui o mesmo valor. Figura retirada de (GLOOR, 1985).

Da mesma maneira, pode-se também realizar esta análise considerando o tecido neural formado por um número de neurônios dispostos em paralelo, como os neurônios do hipocampo. O tecido do córtex está formado por um número de camadas sobrepostas de neurônios como os do hipocampo. Desta maneira, pode-se utilizar esta simplificação sempre que a camada mais superficial corresponder à maior parte da contribuição para o potencial do eletrodo. A Figura 3 ilustra o potencial elétrico de um tecido nervoso formado por uma camada de neurônios dispostos em paralelo.




Figura 3 – Campo elétrico gerado pela excitação de um tecido formado por um número de neurônios piramidais do córtex cerebral. As linhas representam as superfícies isopotenciais geradas pelo tecido. Os ângulos apresentados na figura representam, de maneira bidimensional, os ângulos sólidos que geram os potenciais dos eletrodos. Figura retirada de (GLOOR, 1985).

Se o espaço onde o tecido nervoso está localizado termina, ou encontra uma fronteira com outro meio, podem ser obtidos potenciais diferentes, ainda que esteja-se monitorando o mesmo tecido nervoso, como representado na Figura 4. Nesta figura se apresenta o mesmo tecido nervoso da Figura 3, porém, com uma fronteira que corresponde a uma mudança de meios. Pode-se observar na Figura 4 a curva em forma de sino que representa o potencial capturado pelo eletrodo, de acordo com a sua localização com relação à localização do tecido excitado no meio.

Gloor também cita que os potenciais de ação das membranas somente são possíveis de serem medidos quando os eletrodos estão localizados a distâncias muito pequenas da membrana em estudo. Isto se deve ao fato de que, ainda que o potencial seja elevado com relação ao sinal das sinapses, estes potenciais possuem uma duração muito curta, ao redor de 1 ms , sendo necessário que uma área de tecido nervoso se excite simultaneamente para que o efeito possa ser capturado por um eletrodo externo ao tecido, como um eletrodo




Figura 4 – Campo elétrico gerado pela excitação de um tecido nervoso e os potenciais na fronteira do meio onde este tecido está localizado. Figura retirada de (GLOOR, 1985).

colocado sobre o couro cabeludo, por exemplo.

O potencial que se captura com EEG é o potencial das sinapses, que, ainda que sejam mais baixos que os potenciais de ação, são mais lentos e ocorrem em maiores extensões de tecido simultaneamente. Deste modo, o eletrodo se torna sensível à integração deste potencial, mesmo que seja de uma amplitude mais baixa.

Vale ressaltar que as características do sinal capturado varia com a tecnologia utilizada no posicionamento do eletrodo. De acordo com a Figura 5, é possível observar que o sinal de um eletrodo utilizado para captura de sinais EEG representa a atividade de uma área sob o eletrodo. Nesta mesma figura é possível observar que outras tecnologias mais intrusivas representam a atividade de áreas menores do córtex cerebral.

Além de representarem a atividade de áreas distintas do cérebro, os sinais de eletrodos implantados também apresentam características de amplitude e frequência muito distintas às do sinal EEG. A banda de frequências do sinal EEG apresenta frequências entre ≈ 0 e 50 Hz (MALMIVUO; PLONSEY, 1995), enquanto que os sinais de eletrodos implantados apresentam frequências na faixa de 5 a 10 kHz (SCHWARTZ et al., 2006; IFFT et al., 2013).

Com relação à amplitude, segundo (SCHWARTZ et al., 2006), a amplitude dos




Figura 5 – Área coberta por um determinado tipo de eletrodo utilizado para a captura de dados utilizados em ICCs. EEG: Eletrodo posicionado sobre a pele (couro cabeludo); ECoG: Eletrodo posicionado sobre as meninges; *Local F.P.*: eletrodo posicionado sob as meninges; *Single Unit A.P.*: eletrodo posicionado sobre um único neurônio. Figura retirada de (SCHWARTZ et al., 2006).

sinais EEG pode chegar à faixa de milivolts, já os valores dos eletrodos implantados chegam a picovolts, ainda que com uma melhor relação sinal ruído que os sinais EEG. Esta diferença se deve ao fato de que um eletrodo implantado recebe sinais de poucos neurônios enquanto que um sinal EEG está sujeito a contribuições de áreas adjacentes à área de interesse, sendo este sinal conduzido pelos tecidos até o eletrodo.

2.1.4 A organização somatotópica do cérebro

O cérebro humano apresenta regiões dedicadas a algumas tarefas específicas. Entre estas tarefas se encontra o processamento da informação dos diferentes sentidos: a memória, as ações conscientes, a coordenação motora, entre outras. Estas regiões se formam internamente seguindo uma estratégia de agrupamento de neurônios em zonas dedicadas a funções similares, o que parece ser importante para o processamento espacial da informação no cérebro (GLUCK; MYERS, 2000; PEREIRA; REIS; MAGALHÃES, 2003).

O cérebro se divide basicamente em duas partes, denominadas córtex ou matéria cinza, localizadas na periferia do cérebro, e matéria branca, localizada no interior do cérebro. Estas partes se diferenciam por suas funções básicas: enquanto o córtex possui a função básica de processar a informação aferente do resto do corpo, a matéria branca possui a função básica de prover a comunicação entre os distintos pontos do córtex e o resto dos neurônios do corpo (PEREIRA; REIS; MAGALHÃES, 2003).

A Figura 6 representa as conexões do córtex com os membros através da medula. A figura também representa uma característica das conexões entre os membros e o córtex, onde o lado direito do córtex reflete as informações dos membros do lado esquerdo, e vice-versa.




Figura 6 – Conexões entre os neurônios e o córtex cerebral através da medula. Figura adaptada de Gray (GRAY, 1918).

Uma vez que as zonas do cérebro responsáveis por tarefas similares, como o controle motor ou as funções sensoriais, se agrupam em zonas no córtex cerebral, pode-se representar estas áreas de maneira simplificada pelos denominados homúnculos sensoriais e motores (Figura 7). Entretanto, esta representação já é considerada ultrapassada, já que estas áreas não se encontram completamente separadas entre si, sendo que uma representação mais próxima à realidade representaria uma estrutura mais dinâmica e mais próxima a um mosaico, no qual haveriam regiões que realizariam mais de uma função. Outra característica não representada nos homúnculos é a capacidade de reorganização do cérebro, chamada plasticidade neural, onde a estrutura pode se reorganizar até um determinado nível com o fim de suprir alguma deficiência em alguma parte do cérebro, ou do corpo, como no caso de uma deficiência. A Figura 7 representa então a posição aproximada das zonas do cérebro responsáveis pelo controle motor das diferentes áreas do corpo. No caso das zonas responsáveis pelo processamento da informação sensorial, as regiões representam as áreas responsáveis por este processamento.

Pode-se observar nesta representação que as mãos possuem uma maior área dedicada a seus movimentos, sendo sua sensibilidade muito maior que as dedicadas ao resto do braço, o que demonstra a complexidade da estrutura das mãos. Assim, no caso do desenvolvimento de uma ICC que utilize os sinais capturados durante atividades cerebrais




Figura 7 – Homúnculo representando a posição no córtex cerebral das distintas funções sensoriais ou motoras. Figura adaptada de (PENFIELD; RASMUSSEN, 1950).

relacionadas aos movimentos das mãos, as posições mais recomendadas seriam as localizadas acima das regiões marcadas pelos homúnculos, referentes ao movimento das mãos, as quais correspondem às posições C3 e C4 no sistema 10/20, representado na Figura 8.

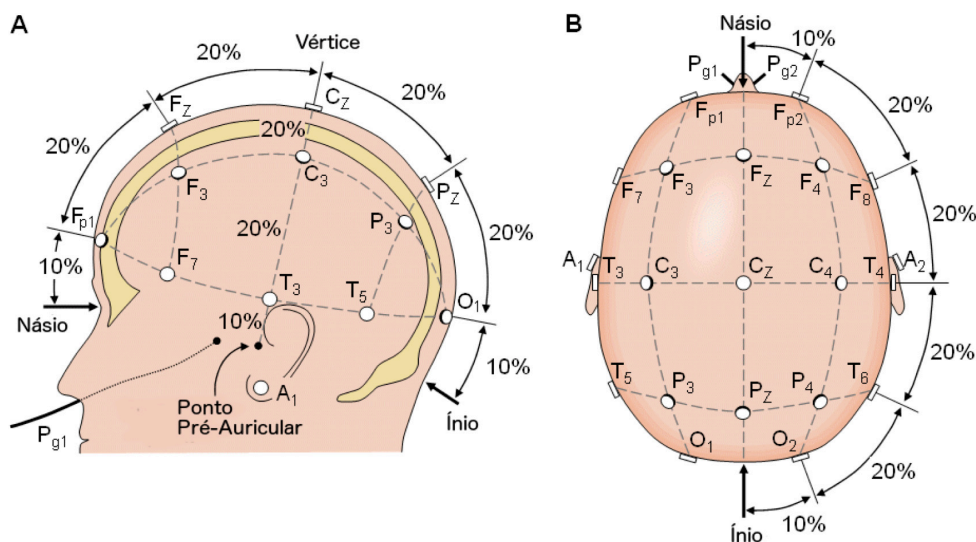


Figura 8 – Posicionamento dos eletrodos de acordo com o sistema internacional 10/20 (Adaptada de Malmivuo, (MALMIVUO; PLONSEY, 1995)). Em A, vista lateral, e em B, vista superior. As regiões correspondem a Pg: Nasofaringeal; A: Auricular; Fp: Frontal Polar; F: Frontal; C: Central; T: Temporal; P: Parietal; O: Occipital.

Outros sistemas de ICC utilizam a zona responsável pela interpretação da informação visual, localizada na região dos eletrodos O1 e O2 do sistema 10/20. A região occipital do cérebro, onde se encontram estes eletrodos, é responsável pelo processamento da informação visual, sendo que o nível de atividade desta região pode ser medido através da energia do sinal EEG capturado. Com base na variação desta energia pode-se identificar se a pessoa está, por exemplo, de olhos abertos ou fechados, concentrado ou relaxado (FERREIRA, 2008), ou ainda se está recebendo um estímulo luminoso de frequência co-

nhecida, tal como utilizado na técnica SSVEP (COTRINA et al., 2014). Variações nos tipos de ICC existentes na bibliografia são apresentados com mais detalhes na seguinte seção.

2.2 Tipos de ICCs

As interfaces cérebro-computador (ICCs) podem ser classificadas de diferentes maneiras, sendo uma delas referente à maneira como os sinais capturados são gerados, por exemplo, se são gerados de forma espontânea pelo usuário e capturados pelo sistema, ou em resposta a um evento ou estímulo externo.

De acordo com esta divisão, as ICCs são classificadas como síncronas ou assíncronas. Um sistema é dito síncrono se este se baseia em identificar mudanças nos sinais de EEG em resposta a estímulos sensoriais externos, os quais podem ser de qualquer tipo, sendo os tipos mais comuns os auditivos e os visuais. Um exemplo deste tipo de interface é o que utiliza o paradigma de identificação do potencial P300 que ocorre em resposta a um estímulo esperado. Este estímulo pode ser um som, ou a seleção de um ícone em uma tela. Se esta seleção for aguardada pelo usuário, o potencial acontecerá (DORNHEGE, 2006; NICOLAS-ALONSO; GOMEZ-GIL, 2012; ITURRATE et al., 2009; CAPATI; BECHELLI; CASTRO, 2016). Como este potencial ocorre apenas aproximadamente 300 ms após a apresentação do estímulo, ICCs com esta característica são caracterizadas como síncronas, pois a resposta do usuário depende do estímulo gerado pela ICC.

Um outro exemplo de ICC síncrona é a que utiliza a sincronização dos potenciais evocados visuais no córtex visual, denominados “Potenciais Evocados Visuais de Estado Estacionário” (*Steady State Visual Evoked Potential - SSVEP*), os quais são normalmente observados na região occipital e refletem a frequência dos estímulos visuais apresentados ao usuário. Este tipo de ICC pode ser usado para selecionar uma alternativa entre várias, desde que as alternativas tenham frequências diferentes e conhecidas (MÜLLER, 2012; COTRINA et al., 2014; COTRINA; CASTILLO; BASTOS FILHO, 2014; ATENCIO, 2015; TELLO, 2016).

Diferentemente dos casos anteriores, ICCs assíncronas (como a utilizada nesta Tese de Doutorado) não utilizam a resposta a eventos externos para buscar as características do sinal EEG, gerando saídas apenas quando encontram as características adequadas, as quais podem interpretar as intenções do usuário quando este realize a tarefa mental selecionada. Estas ICCs são mais naturais que as ICCs síncronas, já que o usuário não precisa ter a atenção focada na interface de um dispositivo para que possa interagir com o sistema e gerar os sinais de controle, entretanto são muito mais complexas que as síncronas.

Ambos os tipos de ICCs podem ser utilizadas em qualquer situação, embora a interação entre o usuário e a ICC se torne mais natural nas ICCs assíncronas, mesmo que

esta implementação tenha um custo computacional mais elevado. Um exemplo de ICC assíncrona é apresentada por Fabiani (FABIANI et al., 2004), a qual utiliza eletrodos implantados no córtex motor de um sujeito, com a finalidade que o usuário possa mover um cursor na tela do computador como se estivesse utilizando um *mouse* comum conectado ao computador. Em (HJORUNGDAL et al., 2016) o autor apresenta o desenvolvimento de um ambiente virtual para o treinamento de usuários de uma ICC assíncrona, onde o mesmo deve guiar uma cadeira de rodas pelo ambiente virtual.

A ICC desenvolvida nesta Tese de Doutorado é do tipo assíncrona, baseada na intenção de movimento de um sujeito, pois acredita-se que esta forma de utilização se torna mais natural para um sujeito, embora demande mais recursos, como mais canais EEG e técnicas de processamento de sinais mais elaboradas (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Por outro lado o usuário não é fatigado com estímulos, como no caso das síncronas, tornando o seu uso menos cansativo.

2.3 Características do sinal EEG utilizadas em ICC

Os sinais EEG possuem várias características diretamente relacionadas com os diferentes estados do cérebro. Entre estas podem-se identificar claramente dois grandes grupos: os potenciais característicos, como os potenciais relacionados a eventos (*Event Related Potential* - ERP) e as frequências características como as sincronizações/desincronizações relacionadas a eventos (*Event related synchronization/desynchronization* - ERS/ERD). A seguir são detalhados esses dois tipos de características.

2.3.1 Potenciais Característicos

Como comentado anteriormente, o sinal capturado no couro cabeludo está formado pela interação dos distintos potenciais gerados por cada uma das células no tecido do cérebro. A coordenação da ativação de um determinado grupo de neurônios provoca o aparecimento de um potencial no couro cabeludo denominado EEG (WARD, 2003). Se esta coordenação é duradoura, a variação de potencial observada é lenta, sendo que esta variação recebe o nome de “potencial”. Mudanças rápidas no sinal geram componentes de frequência que também são utilizadas como características do sinal, as quais serão tratadas na subseção seguinte. Ainda que o mecanismo que gera os sinais rápidos e lentos seja essencialmente o mesmo, podem-se tratar ambos como processos diferentes.

Os potenciais podem ter diferentes origens, entre as quais a intenção de movimento, os potenciais relacionados ao reconhecimento de condições esperadas (como o P300), os potenciais relacionados ao reconhecimento consciente de erros e os potenciais relacionados à realização de movimentos. Em geral, os potenciais ocorrem como uma resposta

a um estímulo e caracterizam uma decisão consciente do sujeito (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Os potenciais de intenção de movimento (em alemão, *Bereitschaftspotential*, em inglês, *Readiness Potentials*) ocorrem durante a preparação para a realização dos movimentos, reais ou imaginados, e se caracterizam por uma elevação nos potenciais sobre o córtex pré-motor, sendo que esta característica é mais pronunciada no hemisfério oposto ao membro que executa o movimento. Assim, esta característica pode ser utilizada como variável para a identificação das intenções de movimento com antecedência à execução do mesmo, uma vez que estes potenciais ocorrem entre 750 e 500 ms antes da ativação dos músculos responsáveis pela execução do movimento (DORNHEGE, 2006; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Já os potenciais denominados P300 ocorrem como resposta a um estímulo externo aguardado pelo sujeito, sendo detectados aproximadamente 300 ms depois da apresentação do estímulo visual ou auditivo, e se caracterizam por ser uma elevação positiva no potencial nas regiões dos lóbulos parietal ou occipital, responsáveis pela interpretação destes estímulos (DORNHEGE, 2006; NICOLAS-ALONSO; GOMEZ-GIL, 2012; CAPATI; BECHELLI; CASTRO, 2016).

Os potenciais de erro estão diretamente relacionados com a auto-avaliação das atividades, possuindo uma estrutura similar à estrutura do potencial P300, sendo compostos por uma oscilação negativa (*error negativity*) seguida por uma oscilação positiva (*error positivity*) que se assemelha ao P300. A oscilação positiva somente se manifesta nas situações de erro, enquanto que a negativa se manifesta também nas situações onde o usuário executa corretamente a tarefa, sendo que em situações de erro, a oscilação negativa apresenta maior amplitude, quando comparada com situações sem erro (DORNHEGE, 2006). Assim, esta oscilação relacionada com a avaliação das atividades por parte do próprio sujeito pode ser utilizada para validar ou não uma determinada ação executada pela ICC ou para o treinamento da mesma baseando-se apenas na resposta do usuário. Inclusive, alguns grupos de pesquisa utilizam o potencial de erro para a avaliação da classificação e correção das saídas em tempo real, melhorando a ICC enquanto o sujeito se adapta à mesma (FERREZ; MILLÁN, 2005; BUTTFIELD; FERREZ; MILLÁN, 2006).

Por último, os potenciais relacionados à realização dos movimentos se apresentam como variações dos sinais de EEG como resposta aos movimentos realizados pelo sujeito, e são produzidos pela dessincronização da atividade neuronal relacionada a eventos (*Event Related Desynchronization* – ERD) que ocorre em resposta a um evento, neste caso, em resposta a um movimento (DORNHEGE et al., 2002; BENEVIDES; BASTOS FILHO; SARCINELLI FILHO, 2011). Neste caso, as dessincronizações geram uma redução na amplitude dos sinais de repouso do córtex cerebral.

Vale ressaltar que cada um destes potenciais ocorre em áreas específicas do cé-

rebro, devendo ser capturados em diferentes regiões do couro cabeludo. Por exemplo, os potenciais relacionados a movimentos devem ser capturados nas posições C3 e C4, que estão relacionados a movimentos dos membros superiores (ver Figura 8). Por outro lado, o potencial de erro deve ser tomado na região próxima ao vértice da cabeça e sobre o sulco central, próximo ao eletrodo Cz (sobre a região frontal) que é a responsável pelas decisões conscientes (FERREZ; MILLÁN, 2005; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

2.3.2 Frequências características

As frequências características dos sinais cerebrais são utilizadas como ferramentas de diagnóstico desde o início da utilização da eletroencefalografia, sendo que a caracterização das bandas de frequência e a sua associação com algumas situações clínicas, como a epilepsia, são ferramentas importantes para o diagnóstico precoce de algumas doenças e também para o controle de pacientes sob efeito de anestesia em cirurgias.

Estas bandas de frequências estão divididas em conjuntos que apresentam características próprias e estão associadas a algumas atividades mentais. Estas bandas estão nomeadas seguindo o alfabeto grego:

- Alfa (α) – A banda Alfa apresenta frequências entre 8 e 13 Hz (MALMIVUO; PLONSEY, 1995) com um pico de frequência ao redor de 10 Hz. Reduções na potência desta banda estão relacionadas com o aumento da concentração do sujeito ou com a execução de tarefas mentais em geral, e o seu aumento ocorre quando o sujeito fecha os olhos ou está relaxado, principalmente na região occipital.
- Beta (β) – A banda Beta apresenta frequências entre 13 e 30 Hz e reflete a atividade dessincronizada do cérebro. É a banda mais representativa da atividade mental consciente. Por apresentar uma faixa de frequências bastante ampla, a bibliografia costuma dividir esta faixa em três sub-faixas (PRUTCHI; NORRIS, 2005):
 - A banda Beta Baixa, com frequências entre 13 e 15 Hz, a qual contém informação relacionada com estados de alerta relaxados, possui localização bilateral e é inibida em caso de movimento. Uma baixa potência nesta banda é um reflexo de possíveis transtornos de déficit de atenção.
 - A banda Beta Intermediária, com frequências entre 15 e 30 Hz, que contém informação sobre a atividade mental não relacionada ao ambiente ou à resolução de problemas.
 - A banda Beta Alta, com frequências entre 20 e 30Hz, que está associada aos estados de alerta e ao planejamento e resolução de problemas, por exemplo os problemas matemáticos ou o planejamento de tarefas.

- Gama (γ) – A banda Gama apresenta faixa de frequência entre 30 e 50 Hz, sendo 40 Hz a frequência dominante. A banda Gama está presente em todo o cérebro, e está muito relacionada com os processos cognitivos de memória, de atenção e com os estados conscientes em geral. Trabalhos recentes indicam que a banda γ pode estender-se até 80Hz, e pode ser em ICCs (GONZALEZ et al., 2006).
- Delta (δ) – A banda Delta apresenta faixa de frequência entre 0,5 e 4 Hz e ocorre normalmente em situações de sono profundo ou em estados de transe. Está relacionada com estados e atividades subconscientes. A banda Delta é o ritmo predominante em crianças de até um ano de idade. Em pessoas com transtornos de déficit de atenção, ao tentar fixar a atenção em uma tarefa, esta banda aumenta sua energia ao invés de atenuar-se, dificultando a atenção.
- Theta (θ) – A banda Theta apresenta faixa de frequência entre 4 e 8 Hz e está relacionada com os processos cognitivos de memória, imaginação e aprendizagem. Segundo (WARD, 2003), a banda Theta modula a banda Gama nos processos de memorização e recuperação da informação memorizada. A relação entre Gama e Theta também é patente na memória curta ou imediata (*short-time memory*), que é a responsável pela compreensão imediata das tarefas e está envolvida na resolução de problemas.
- Mi (μ) – Os ritmos μ possuem uma frequência dominante ao redor dos 13 Hz e está localizada sobre a região sensorimotora do cérebro (diferentemente dos ritmos Alfa que estão localizados predominantemente na região visual do cérebro). A presença destes ritmos caracteriza uma atividade motora, real ou imaginada, entretanto, estas ondas se confundem com a atividade da banda Beta, dificultando sua identificação.

Na seção seguinte se apresentam alguns dos desenvolvimentos mais importantes na área das ICCs baseadas em sinais EEG.

2.4 Sistemas de aquisição e processamento de sinais EEG

O desenvolvimento de uma interface cérebro computador (ICC) baseada em sinais de EEG, no que se refere à eletrônica, se assemelha ao desenvolvimento de um sistema de aquisição clínico de eletroencefalografia, tendo em vista que os amplificadores empregados em ambos os sistemas possuem características muito similares, no que diz respeito a ganhos, isolamento galvânico do sujeito com relação à rede elétrica, entre outros aspectos.

Devido à necessidade de isolamento galvânico e de segurança para os sujeitos, é muito comum encontrarem-se referências a equipamentos clínicos utilizados em sistemas ICC, uma vez que estes sistemas devem prover esta classe de proteção.

Na Figura 9 se apresenta um esquema simplificado de uma ICC baseada no uso de computadores pessoais. Nesta figura está representado o sujeito, responsável pela geração dos sinais EEG, e o sistema de aquisição, composto por um amplificador e um computador, responsáveis pela captação e processamento dos sinais. O resultado da classificação é apresentado ao sujeito na forma de um estímulo ou ação de um atuador, baseado no resultado da atividade registrada.

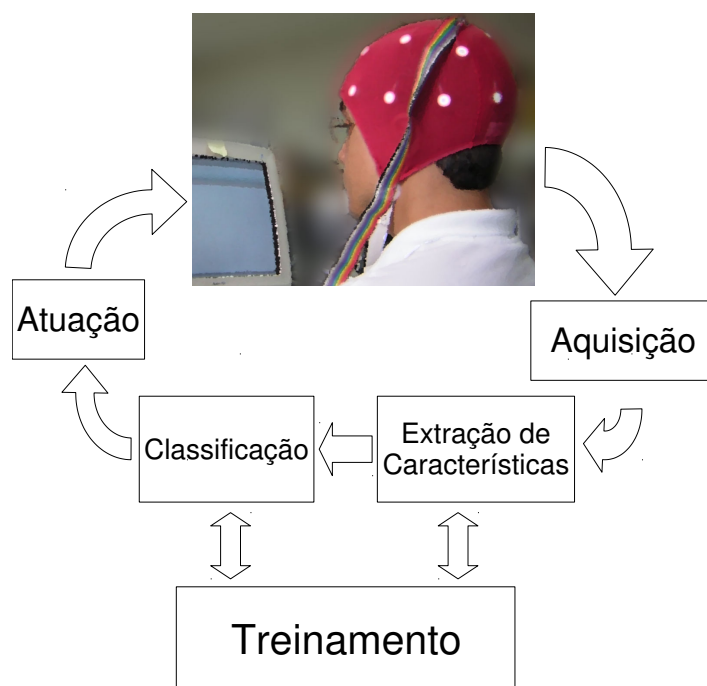


Figura 9 – Esquema simplificado de uma ICC utilizado como base para o desenvolvimento do trabalho. Figura do autor.

Os sistemas clínicos mais atuais de eletroencefalografia utilizam computadores para o registro digital dos sinais, e sua arquitetura aproxima ainda mais os sistemas de controle baseados em sinais de EEG aos sistemas clínicos de captura de EEG para fins de diagnóstico, ao contrário dos sistemas mais antigos que registravam os potenciais em papel (COLLURA, 1993).

A seguir é apresentada a arquitetura eletrônica de um sistema de controle baseado em EEG para, então, descrever o desenvolvimento dos sistemas de processamento e controle de alguns dos sistemas encontrados na bibliografia.

2.4.1 Arquitetura interna dos amplificadores empregados na captura de EEG

Os eletrodos empregados nos sistemas de controle baseados em sinais de EEG, na sua grande maioria, são muito similares aos empregados na aquisição clínica de EEG, pois os eletrodos são do tipo úmido (com gel salino) para que o casamento de impedância entre o eletrodo e o couro cabeludo seja melhor possível, aumentando assim a transferência de energia entre eles, e melhorando a relação sinal/ruído. Existem também no mercado

sistemas que utilizam eletrodos secos para a aquisição de sinais EEG, embora sejam muito mais caros e por isto ainda não estejam muito difundidos (G.TEC, 2017; NICOLAS-ALONSO; GOMEZ-GIL, 2012; MIHAJLOVIC et al., 2015)

A estrutura básica de um amplificador para sinais EEG está representada na Figura 10, onde se pode observar a presença de um amplificador de isolamento no circuito de ganho. Este amplificador é o responsável por eliminar o contato galvânico entre o sujeito e a fonte de alimentação do circuito eletrônico, aumentando o nível de segurança para o sujeito. As etapas de amplificação prévias ao amplificador de isolamento são alimentadas por uma fonte isolada da fonte de energia conectada à rede elétrica.




Figura 10 – Esquema simplificado da estrutura de um amplificador de sinais EEG que cumpre com as necessidades de isolamento do sujeito de forma a garantir a segurança do mesmo contra choques elétricos. Figura do autor.

Por este motivo, os amplificadores necessitam incorporar várias medidas de segurança, tais como as seguintes medidas extraídas do manual de um amplificador clínico que cumpre com os padrões de segurança para isolamento de pacientes (CARDIONICS, 2005):

1. Impedância de entrada maior que 20 M Ω .
2. Isolamento dos eletrodos com relação à entrada da rede elétrica (mínimo de 2500 Vpp).

Com relação ao número de eletrodos utilizados em ICCs, existem trabalhos que usam apenas 2 eletrodos (PFURTSCHELLER et al., 2000; QIN et al., 2005), até os que utilizam uma matriz de 120 canais (DORNHEGE; BLANKERTZ; CURIO, 2003).

Com respeito aos filtros utilizados, como os sinais EEG se caracterizam por apresentar componentes de baixa frequência, como já citado anteriormente (típicamente até 35 Hz), por este motivo, grande parte dos amplificadores clínicos possuem uma frequência de corte superior dos filtros passa-baixas de aproximadamente 40 Hz.

2.4.2 Aquisição dos sinais

Por apresentar frequências características baixas, o sinal EEG não necessita de taxas de amostragem muito elevadas. Na bibliografia estudada, as frequências de amostragem variam entre 128 Hz (MÜLLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999; HSU, 2012; LEE et al., 2004; SILVA-SAUER et al., 2013; FERREZ; MILLÁN, 2005) até uma frequência máxima de 5 kHz (KREPKE et al., 2007), embora existam sistemas comerciais que operam a até 20 kHz (Electrical Geodesics, 2017b). Nos casos de frequências mais elevadas, os sinais são, em geral, sub-amostrados na faixa de 128 a 1 kHz, após serem aplicadas algumas rotinas de processamento de sinal para melhorar a relação sinal/ruído (KREPKE et al., 2007; MIHAJLOVIC et al., 2015).

Com relação à conversão analógico/digital dos sinais, a grande maioria dos sistemas utiliza conversores com resolução a partir dos 12 bits (LIN et al., 2010; SILVA-SAUER et al., 2013; LIAO et al., 2012; POLIKOFF; BUNNELL; BORKOWSKI JR., 1995), a qual se mostra suficiente na maioria das aplicações, embora existam sistemas que operem com conversores de até 24 bits (ALONSO; VELLASCO, 2016; Carino E. et al., 2016).

Um exemplo de sistema comercial de aquisição de dados desenvolvido exclusivamente para ICCs, o ActiveTwo da empresa BioSemi, utiliza um sistema de aquisição em alta frequência baseado em um processador digital de sinais (*Digital Signal Processor – DSP*) para adquirir os sinais EEG em matrizes de eletrodos de até 256 canais utilizando eletrodos ativos (com amplificação de sinais no próprio eletrodo). Este sistema possui uma resolução de 24 bits e frequências de amostragem de até 16 kHz, e conexão USB com um computador (BioSemi Instrumentation, 2003). Outro sistema de aquisição de sinais voltado para ICCs é o sistema desenvolvido pela empresa g.Tec, que possui bibliotecas para interação com o software MatlabTM para que a ICC possa ser desenvolvida utilizando esta plataforma.

Nos laboratórios do NTA–UFES, onde esta pesquisa foi realizada, estão disponíveis para pesquisa de ICCs os equipamentos BrainNet (Lynx Tecnologia, 2013) (feito no Brasil) e Emotiv EPOC (EPOC, 2003). O BrainNet–BNT36 possui 36 canais e uma resolução de 16 bits, podendo operar com diferentes frequências de amostragem, na faixa de 100 a 600 Hz, e configurações de filtros ajustáveis. Este dispositivo possui registro na AN-VISA e conexão com o computador através de uma conexão de rede, tendo sido utilizado para o desenvolvimento deste trabalho. O programa de controle do BNT36 é proprietário e os comandos enviados para o dispositivo através da conexão de rede não são documentados. Assim, foram desenvolvidas rotinas no laboratório que são capazes de gerar estes comandos, permitindo que o equipamento seja utilizado sem o uso do programa original.

Por outro lado, o Emotiv EPOC é um equipamento de captura sem fios capaz de capturar 14 canais de EEG (posições AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8,

FC6, F4, F8, AF4) com uma resolução de 14 bits e a uma taxa de amostragem de 128 Hz. Este dispositivo possui uma conexão sem fios proprietária e os dados são capturados pelo programa proprietário de tratamento do equipamento, podendo ser disponibilizado também para que outros programas como Matlab possam trabalhar com os dados.

2.4.3 Processamento e interpretação de sinais de EEG

Nesta seção é apresentada uma análise breve dos algoritmos de pré-processamento, extração de características e classificação de sinais EEG encontrados na bibliografia, com o intuito de justificar a implementação de nossa ICC. Também são apresentadas as técnicas utilizadas em diferentes ICCs desenvolvidas em alguns dos grupos de pesquisa mais importantes da área.

A extração de características consiste em descrever o sinal EEG utilizando um conjunto de parâmetros que definem este sinal dentro de um espaço de características. Por outro lado, a classificação dos sinais é feita a partir destas características, e busca semelhanças entre este sinal e uma determinada classe já conhecida. Uma análise dos algoritmos aplicados ao desenvolvimento de ICCs será tratado com um maior nível de detalhe no Capítulo 4.

Existe uma grande quantidade de algoritmos desenvolvidos para a extração de características de sinais EEG, cada um deles adaptados a uma determinada arquitetura de aquisição, sendo aqui apresentadas algumas das arquiteturas mais importantes que utilizam de 2 a 120 canais. No que se refere ao número de saídas, uma grande parte da bibliografia apresenta arquiteturas que geram saídas de controle com decisões entre 2 ou 3 classes (que correspondem a uma classe de inatividade, quando presente), e 2 classes de atividades, as quais correspondem às atividades motoras que devem ser identificadas (BASHASHATI; FATOURECHI; WARD, 2007).

2.5 Análise das tecnologias atuais

Esta seção está dedicada à análise dos algoritmos de pré-processamento, extração de características e de classificação de sinais EEG encontrados na bibliografia, desde o ponto de vista de evolução dos algoritmos e os resultados alcançados.

2.5.1 Algoritmos de pré-processamento

Os algoritmos de pré-processamento consistem de uma etapa prévia à extração de características, com o objetivo de minimizar interferências da rede elétrica e limitar a banda de frequência do sinal para otimizar a extração de características.

2.5.1.1 Filtragem temporal e espacial

O pré-processamento dos sinais EEG se concentra na filtragem temporal e espacial dos sinais, gerando sequências temporais com uma melhor relação sinal/ruído que o sinal original. Nesta etapa também se atenuam as bandas de frequência não utilizadas na análise, com o fim de que não interfiram no processo de extração de características.

Entre os diferentes algoritmos de filtragem se encontram os filtros digitais clássicos utilizados em processamento digital de sinais, os quais são utilizados para a adequação da largura de banda do sinal. Como exemplos destes filtros, tem-se os filtros com resposta temporal finita (*Finite Impulse Response – FIR*) e os de resposta temporal infinita (*Infinite Impulse Response – IIR*). Estes filtros apresentam diferentes respostas que podem gerar consequências indesejadas em etapas posteriores no tratamento dos sinais. Por exemplo, para uma mesma característica de frequência de corte e atenuação na banda passante e de atenuação, a ordem de uma implementação FIR sempre será muito maior que a de um filtro IIR, porém, o filtro IIR apresenta uma resposta de fase não linear, o que pode gerar problemas, dependendo do tipo de processamento a ser realizado posteriormente (SMITH, 1997; PROAKIS; MANOLAKIS, 1996).

Filtros espaciais são também utilizados em ICCs, os quais têm por objetivo melhorar a relação sinal/ruído dos canais, levando em consideração a sua localização espacial. Estes filtros realizam uma ponderação entre o sinal de um eletrodo e o sinal dos eletrodos vizinhos, de acordo com a sua posição no couro cabeludo. Desta forma podem-se eliminar potenciais comuns a um determinado grupo de eletrodos (ALONSO; VELLASCO, 2016; CARVALHAES; De Barros, 2015; MCFARLAND, 2015; MÜLLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999; WANG; DENG; HE, 2004; DORNHEGE, 2006). Este tipo de filtragem pode ser aplicado durante a aquisição de sinais EEG, através do uso de amplificadores diferenciais, ou na etapa de pré-processamento digital dos sinais. A aplicação da filtragem espacial durante a aquisição se conhece como aquisição diferencial e é utilizada para eliminar componentes comuns (ruído) aos pontos onde estão conectados os eletrodos, antes mesmo de amostrar os sinais. Com canais muito próximos, o ruído é muito similar, portanto, se esse ruído é atenuado, a relação sinal/ruído melhora.

A utilização dos filtros espaciais em sinais já digitalizadas também pode ser realizada, e igualmente melhora a relação sinal/ruído. Entretanto, o inconveniente desta implementação reside no fato de que se o ruído de fundo tem amplitude muito elevada com relação ao sinal, o sinal e o ruído são amostrados conjuntamente, o que poderia levar a valores muito contaminados com ruído, ou mesmo inviáveis, caso o sistema de aquisição possua uma resolução baixa. Os filtros espaciais são também chamados filtros de Laplace (KAYSER; TENKE, 2015).

Para o tratamento de sinais EEG, os sinais dos eletrodos são organizados de modo

a formar uma matriz que representa aproximadamente a disposição física dos eletrodos no couro cabeludo para que o algoritmo gere os resultados esperados, sendo o filtro então aplicado a cada amostra. O filtro de Laplace tem comportamento similar a um filtro passa-altas, pois evidencia as diferenças entre os pontos vizinhos.

Quando esta técnica é aplicada a sinais EEG, pode-se observar uma diminuição do potencial comum ao conjunto de eletrodos utilizado devido à característica passa-altas do filtro (KAYSER; TENKE, 2015). Na Figura 11 podem-se observar os efeitos da aplicação do filtro de Laplace a uma amostra de sinal de EEG. A figura foi gerada a partir de uma interpolação de uma matriz de 32 canais sobre uma grade de 67x67 pontos, utilizando a ferramenta EEGLab (DELORME; MAKEIG, 2004). Na Figura 12 está representada a evolução temporal dos sinais adquiridos antes e depois da aplicação do filtro de Laplace ao conjunto de sinais.




Figura 11 – Exemplos de aplicação de filtros de Laplace em imagens representando os potenciais de sinais de EEG. Representação dos potenciais originais, em (a). Em (b) e em (c) estão representados os resultados da aplicação dos respectivos filtros de Laplace. Figuras do autor.

Pode-se observar que o resultado da aplicação do filtro mostrado na Figura 12 elimina algumas componentes comuns do sinal original, as quais não agregam informação e podem ser eliminadas sem prejudicar o processo de extração de características. A localização dos eletrodos utilizados para a captura dos sinais apresentados anteriormente está mostrada na Figura 13.

A aplicação do filtro de Laplace implica na utilização de pontos ao redor do ponto de interesse para o cálculo do novo ponto de interesse. Nas bordas da matriz de eletrodos não existem pontos em toda a vizinhança do ponto de interesse. Neste caso, podem ser adotadas diferentes estratégias, como a repetição dos vizinhos do lado oposto onde não existem vizinhos, a reprodução na saída dos valores originais, ou a deformação da

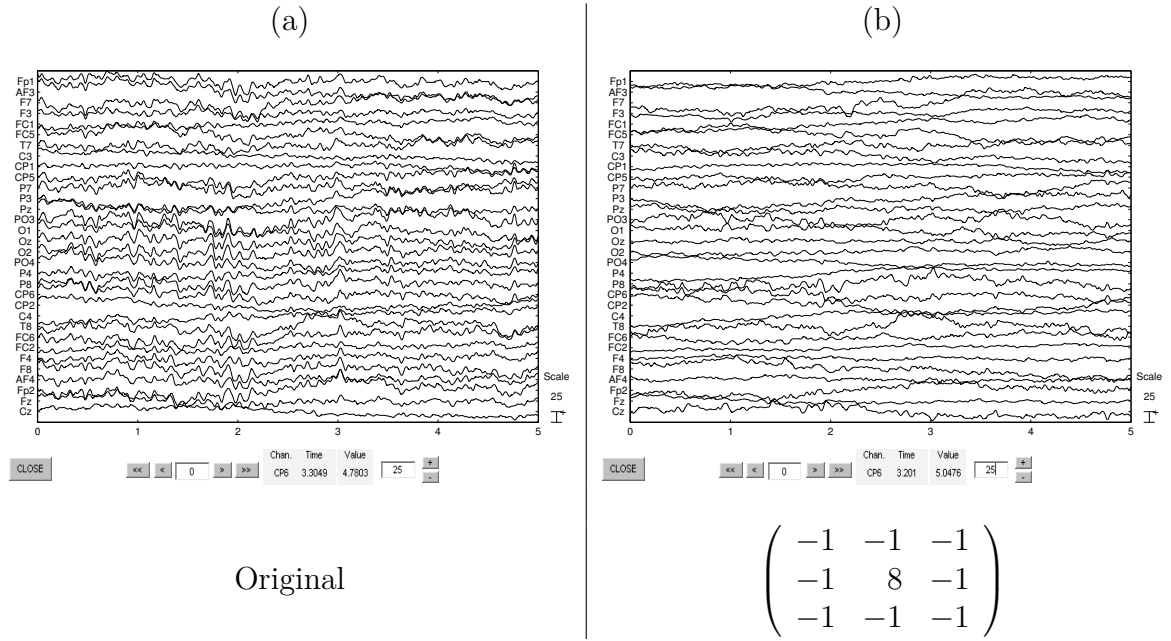


Figura 12 – Exemplos de aplicação de filtros Laplace em séries temporais que representam os potenciais dos sinais EEG. Representação dos potenciais originais, em (a). Em (b) está representado o resultado da aplicação do filtro de Laplace. Figuras do autor.




Figura 13 – Disposição dos eletrodos utilizados para a aquisição dos sinais representados nas Figuras 12 e 11. Figura adaptada de (MALMIVUO; PLONSEY, 1995).

matriz do filtro e a aplicação de um ganho de normalização (MCFARLAND, 2015; CARVALHAES; De Barros, 2015). Este último enfoque foi utilizado para a geração dos dados apresentados na Figura 12.

2.5.1.2 Análise de componentes principais – PCA

Em alguns casos se podem aplicar algoritmos de projeção com o fim de reduzir as dimensões das matrizes de sinais adquiridas. Um dos algoritmos utilizados para este fim é o algoritmo de análise de componentes principais (Principal Component Analysis – PCA) (LEE et al., 2004; ALONSO; VELLASCO, 2016). Com este algoritmo gera-se uma nova base vetorial formada por um conjunto de vetores ortogonais, utilizando um espaço formado pelo conjunto de autovetores do conjunto de dados originais. Com esta decomposição se obtém um espaço cuja base são componentes ortogonais, e a informação se concentra em algumas das componentes deste novo espaço vetorial. Com base nesta nova distribuição da informação, podem-se eliminar algumas das componentes sem prejudicar a quantidade de informação contida na matriz de dados original através da eliminação de componentes irrelevantes (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Desta forma, o conjunto de dados final terá uma dimensão menor que a do espaço original, mantendo a maior parte da informação contida no conjunto de dados original. A reconstrução dos dados a partir deste subconjunto pode ser utilizada, apresentando baixos níveis de erro com relação ao dados originais, desde que as componentes eliminadas sejam as de menor informação associada (DORNHEGE et al., 2004b; DORNHEGE; BLANKERTZ; CURIÓ, 2003; MÜLLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999; PFURTSCHELLER et al., 2000; RAMOSER; MÜLLER-GERKING; PFURTSCHELLER, 2000; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Assim, PCA pode ser utilizado para a compressão de séries temporais de grandes dimensões, onde se pode perder uma pequena quantidade de informação sem comprometer a informação principal. Por outro lado, devido à grande quantidade de dados a serem processados, o sistema pode ter sua performance diminuída pelo aumento do custo computacional associado ao processamento dos dados em sua dimensão original. Neste caso, pode-se processar a projeção de menor dimensão formada pelo autovetores com maiores autovalores associados, os quais retêm a maior parte da informação do conjunto de sinais originais (SHLENS, 2005).

De acordo com (SHLENS, 2005), a geração dos vetores de componentes principais é gerada a partir de uma transformação dos vetores de sinal, sendo que a matriz de transformação é gerada à partir dos autovetores da matriz de covariância ordenados de acordo com o valor dos autovalores associados. Desta forma os vetores de componentes principais são ordenados de acordo com a variância associada a cada autovetor.

A projeção dos dados originais sobre um subconjunto dos n autovetores com maiores autovalores associados é ótima em termos de erro médio quadrático. Em outras palavras, a projeção a um subespaço de menores dimensões e a sua reconstrução ao espaço original possui um erro de reconstrução mínimo. Caso a matriz de projeção contenha todos os autovetores associados a autovalores não nulos, o erro de reconstrução é zero


(BAEK et al., 2002; SHLENS, 2005).

O procedimento de cálculo do PCA, como apresentado, é um procedimento analítico bem definido e pode ser implementado sem grandes complicações, mas devido ao fato de se necessitar de um conjunto de dados para caracterizar a matriz de projeção, esta etapa deve ser realizada *offline*. Para a implementação deste algoritmo em um sistema de tempo real, estimamos que somente as matrizes de projeção sejam utilizadas, as quais deveriam ser calculadas previamente e implementadas no sistema. Esta implementação seria estática, ou seja, esta matriz não se alteraria durante todo o tempo em que o usuário utilizasse o sistema. Para uma implementação adaptativa utilizando o algoritmo apresentado, seria necessário o armazenamento dos dados adquiridos, sendo necessário o recálculo da matriz de projeção após algumas iterações. Além disso, informações a respeito da tarefa deveriam ser adquiridas de maneira que os classificadores pudessem ser melhorados. Esta necessidade implicaria na necessidade de uma capacidade de armazenamento de uma quantidade grande de dados para a execução do algoritmo, além de elevar o custo computacional e a capacidade de memória do dispositivo. Uma implementação do algoritmo como apresentado em (NIE; WARMUTH, 2016) pode ser uma alternativa para a utilização de PCA para redução da dimensionalidade em sistemas *online*.


Um outro problema detectado na implementação do algoritmo PCA é a sua sensibilidade ao ruído / artefatos no sinal EEG, pois em algumas situações a relação sinal/ruído é muito desfavorável, principalmente quando ocorrem artefatos, que são sinais que interferem no EEG. Outro problema detectado nos testes com PCA é que algumas componentes principais podem possuir componentes de frequência com energia muito mais baixa no sinal original, o que pode gerar dificuldades adicionais, pois a análise de frequências necessitaria de alterações com relação à análise feita com os sinais originais, sendo que esta nova distribuição de frequências deveria ser gerada para cada matriz de projeção.

Devido à grande quantidade de ruído / artefatos normalmente presente no sinal EEG, um enfoque diferente do tradicional foi utilizado neste trabalho para o emprego do algoritmo PCA para o processamento de sinais EEG, consistia na remoção de artefatos, tal como feito em (TURNIP; JUNAIDI, 2014). Neste enfoque, se eliminou a componente de maior energia do sinal, já que, ao eliminar-se esta componente, se elimina uma grande parte da energia do ruído/artefato. Assim, a reconstrução do sinal ao espaço original devolve o sinal correspondente às ativações nervosas com menos contaminação dos artefatos. Estes sinais podem ser observados na Figura 14, que mostra o sinal original, em (a), e o sinal reconstruído pelo algoritmo PCA, em (b).

Pode-se observar também na Figura 14 que a oscilação ao redor do tempo $t = 1s$ (devido a algum artefato), presente nos dados originais, foi fortemente atenuada nos sinais filtrados utilizando PCA. Também se observa que os sinais originais apresentam componentes comuns de alta frequência que foram atenuadas com a aplicação do filtro



(a)



(b)

Figura 14 – Aplicação do algoritmo PCA como filtro para remoção de artefatos dos sinais EEG. Figuras do autor.

baseado na aplicação de PCA.

Um procedimento similar foi utilizado em (HOYA et al., 2003), onde foi utilizado um canal de EOG com um ganho maior que os canais de EEG. Neste caso, após o cálculo da matriz de projeção, se elimina a componente de maior energia que se aproxima muito do sinal de EOG capturado. Desta forma o autor logra atenuar a influência do EOG nos canais EEG. Nos testes realizados, nesta pesquisa, apesar de a estrutura do artefato não ser conhecida, se assume que este possui uma grande energia, e que este ruído é uma componente comum a todos os canais, sendo assim uma das componentes principais do

sinal.

A análise de componentes principais (PCA), da forma como foi apresentada, mostrou-se uma ferramenta com grande potencial para a análise e refinamento dos sinais EEG como um algoritmo de pré-processamento, porém, o algoritmo apresenta algumas limitações à aplicação em um sistema BCI *online*, listadas a seguir: as componentes mais relacionadas à tarefa não necessariamente estarão entre as componentes com maior variância (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Como o algoritmo está baseado na utilização de um conjunto de autovetores que são calculados a partir de dados previamente adquiridos, se as condições do sujeito mudam, pela aprendizagem, por exemplo, as componentes sobre as quais se projetam os dados adquiridos já não correspondem às componentes selecionadas previamente para a aplicação com os dados de treinamento, o que pode ser atenuado com a implementação de um algoritmo PCA *online* como o apresentado em (NIE; WARMUTH, 2016). O algoritmo pode adicionalmente ser utilizado para a redução de artefatos (TURNIP; JUNAIDI, 2014; NICOLAS-ALONSO; GOMEZ-GIL, 2012) e também para a redução da dimensionalidade do problema através da redução do número de canais ou do número de características analisadas (NICOLAS-ALONSO; GOMEZ-GIL, 2012; SRIDHAR; RAO, 2012).

Neste trabalho optou-se por um processamento dos dados sem eliminação prévia de artefatos, no qual as características foram selecionadas utilizando um método de escolha, descartando assim o uso de PCA.

2.5.1.3 Análise de componentes Independentes – ICA

Outro algoritmo de projeção também utilizado em ICCs é a análise de componentes independentes (Independent Component Analysis – ICA). Este algoritmo busca gerar uma projeção do sinal capturado sobre um novo espaço, formado por vetores não necessariamente ortogonais, mas que geram séries temporais estatisticamente independentes, como resultado da projeção (HYVÄRINEN; OJA, 2000; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

A matriz de projeção calculada pelo algoritmo pode ser interpretada como a inversa de uma matriz que toma uma série de sinais independentes entre si e forma o sinal capturado. Desta forma, podem se identificar artefatos, como os gerados por movimentação dos eletrodos, piscadas de olhos, entre outros, que possuem características muito diferentes das características do sinal EEG. Assim, a reconstrução do sinal sem estes ruídos pode ser utilizada para a obtenção de um sinal EEG mais “limpo” (DELORME; MAKEIG, 2004; KIM et al., 2017).

O algoritmo ICA é muito comum nos trabalhos onde se busca a identificação de um conjunto de dipolos que possam gerar a distribuição dos potenciais adquiridos pela ICC (PION-TONACHINI et al., 2015; CHIAPPA; BARBER, 2005; WENTRUP et al.,

2005; BUENO et al., 2006; HOYA et al., 2003; QIN; DING; HE, 2004). Nesses trabalhos se gera uma projeção de componentes independentes e, a partir destas componentes, se gera uma nova distribuição de potenciais para a determinação de um dipolo equivalente dentro do volume do cérebro, considerando um modelo de condutor volumétrico para o cérebro.

O algoritmo ICA foi desenvolvido para solucionar problemas de identificação de séries temporais quando só se tem acesso a uma mistura destas séries. O problema clássico da aplicação do algoritmo é a identificação cega dos diferentes interlocutores em um discurso, a partir da mescla capturada por diferentes microfones dispostos em um mesmo ambiente. Este problema é conhecido como *The cocktail party problem* (HYVÄRINEN; OJA, 2000).

Como se dispõe unicamente das amostras de dados reais e não se conhecem as amostras das componentes independentes nem a matriz de projeção dos sinais independentes para gerar os sinais capturados, deve-se estimar tanto as componentes independentes como a matriz de projeção (HYVÄRINEN; OJA, 2000).

O algoritmo possui algumas ambiguidades que são listadas a seguir (HYVÄRINEN; OJA, 2000):

1. Não se pode determinar, *a priori*, as variâncias das componentes independentes. Como a matriz de projeção e a série temporal das componentes independentes não são conhecidas, não se pode determinar a variância das componentes porque qualquer fator multiplicativo aplicado a uma das componentes pode ser cancelado na matriz de projeção. Como as componentes independentes são variáveis aleatórias, assume-se que todas as componentes tenham variância unitária. Neste caso, a matriz de projeção é definida para a geração de componentes com variância unitária.
2. Não se pode determinar com precisão a fase dos sinais. Da mesma forma que uma mudança na matriz de projeção pode gerar uma mudança de variância sem mudar a independência entre os sinais, uma mudança na mesma matriz pode causar uma mudança de fase, sem alterar a independência.
3. Não se pode determinar a ordem das componentes independentes. Por não se conhecer os valores das séries temporais independentes e da matriz de projeção, pode-se alterar a ordem das componentes livremente, com as respectivas mudanças na matriz de projeção, e escolher qualquer uma das componentes como a primeira. Matematicamente, pode-se adicionar uma matriz de permutação à matriz das componentes independentes na definição da matriz de projeção.

Esta ferramenta foi útil em análises manuais, mas na avaliação realizada para a viabilidade de implementação não supervisionada, não foi verificada a sua viabilidade,

devido ao elevado custo computacional para a atualização da matriz de projeção, visto que o algoritmo de geração da matriz, como apresentado, é um método iterativo e possui a característica de não concentrar o ruído em uma componente específica, o que dificulta a identificação automática de ruído .

2.5.2 Extração de características

Os algoritmos de extração de características são de extrema importância no desenvolvimento de uma ICC porque o sinal EEG possui uma grande quantidade de ruídos/artefatos associados, além de ser formado pela integração da atividade de um grande número de fontes de informação no interior do cérebro, como já citado anteriormente (DIAS; MENDES; CORREIA, 2008).

Assim, um algoritmo para a extração de características deve ser capaz de evidenciar mudanças sutis no sinal devido à execução de uma determinada tarefa mental, a qual pode estar associada a movimentos, reais ou imaginários, à evocação de imagens, à execução mental de cálculos matemáticos, entre outros.

Estes algoritmos podem utilizar diferentes características dos sinais, como as mudanças na energia das diferentes bandas de frequência observadas nos sinais EEG (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Para evidenciar a atividade no domínio da frequência, podem-se aplicar várias ferramentas, entre elas o cálculo da energia das diferentes bandas do sinal através da transformada de Fourier, a qual permite que se procure por mudanças na atividade com a precisão desejada, porém, requer uma janela de amostras de dimensões adequadas e relacionada com a precisão desejada.

Em trabalhos nossos anteriores, (BUENO; PONS, 2006), foi apresentado um algoritmo capaz de identificar o instante no qual o sujeito inicia uma atividade mental analisando as variações na energia das bandas de frequência dos sinais EEG. Esta análise utiliza a transformada de Fourier como característica, além da correlação como ferramenta matemática básica. Este algoritmo é relevante para o desenvolvimento desta Tese de Doutorado e será detalhado no Capítulo 4.

Alguns trabalhos apresentam a utilização de Wavelets para a extração de características e classificação dos estados mentais associados à imaginação de movimentos (ALONSO; VELLASCO, 2016; CASTILLO et al., 2014; PEI; ZHENG, 2008). Embora este algoritmo não tenha sido utilizado no desenvolvimento desta Tese de Doutorado ele foi verificado como uma possível alternativa para a extração de características.

Outro algoritmo citado na literatura para a extração de características de frequência dos sinais EEG são os filtros passa-banda sintonizados em uma determinada banda de frequência. Estes algoritmos são utilizados para determinar mudanças na atividade registrada em um determinado número de eletrodos (NICOLAS-ALONSO; GOMEZ-GIL,

2012; DIAS; MENDES; CORREIA, 2008; RANAWEERA; TALAVAGE; KRISHNAN, 2005; QIN et al., 2005; QIN; DING; HE, 2004), sendo que para o cálculo das características, associam-se valores a janelas predeterminadas dos sinais filtrados por estes filtros passa-banda. Os valores das janelas são calculados utilizando-se a norma quadrática desses valores.

A análise de frequência dos sinais EEG envolve um certo conhecimento *a priori* da distribuição das frequências relacionadas a uma determinada tarefa mental, para um determinado sujeito, além da localização espacial da mesma para que se otimize o sistema de aquisição e classificação, o que ainda é um problema não resolvido. Para atividades relacionadas a ações motoras, conhece-se aproximadamente a zona do cérebro que, em geral, é ativada para a execução deste tipo de tarefas, sendo que a região do córtex responsável por estas tarefas mentais é conhecida como córtex motor e está localizada à frente da estrutura denominada *central sulcus*, portanto, na região coberta pelos eletrodos C3 e C4 do padrão 10/20 de posicionamento de eletrodos para eletroencefalografia (ilustrado na Figura 8). As Figuras 15 (a) e 15 (b) apresentam as principais regiões do cérebro.




Figura 15 – Em (a) Representação do cérebro humano indicando as regiões mais importantes. Em (b) Representação do cérebro humano indicando as regiões mais importantes com mais detalhe. Ambas as figuras foram adaptadas da versão digital do livro *Gray's anatomy*, 1918 (GRAY, 1918) disponível *on-line* e de domínio público.

Um enfoque utilizado em algumas publicações da Universidade de Graz utiliza a modelagem do sinal EEG através de um modelo autorregressivo adaptativo (*Adaptive Autoregressive* – AAR) (SHEDEED; ISSA, 2016; HUAN; PALANIAPPAN, 2005; PFURTSCHALLER et al., 2000), o qual tem por objetivo gerar um modelo polinomial para o sinal EEG com um erro mínimo, utilizando um polinômio de ordem pré-estabelecida.

Este método é utilizado para poucos eletrodos e pode gerar quantas características sejam necessárias, já que o número de características corresponde à ordem do modelo gerado. Por outro lado, a ordem do modelo está diretamente ligada à representação do sinal, sendo que uma ordem mais elevada representa o sinal com um maior nível de

detalhes, podendo evidenciar mudanças mais sutis ou frequências mais elevadas no sinal. Assim, ordens muito elevadas podem gerar polinômios que modelem o ruído/artefato presente no sinal. Em (PFURTSCHELLER et al., 2000), o autor utiliza um modelo AAR de ordem 5 como gerador de características para a classificação entre duas classes. Nos experimentos realizados, utilizando realimentação ao sujeito, é apresentada uma taxa de acerto de 91%, para dados classificados em duas classes. Em (SHEDEED; ISSA, 2016) foi utilizado um modelo de ordem 30 para cada canal, gerando 120 características, gerando uma taxa de acerto de 85,5%.

Outro enfoque presente na literatura é a utilização de modelos de dipolos como características para a classificação da atividade mental de imaginação de movimentos (QIN; DING; HE, 2004; WENTRUP et al., 2005; PION-TONACHINI et al., 2015). Para isto, utilizam-se os potenciais captados para determinar a localização de um conjunto limitado de dipolos que poderiam gerar um potencial equivalente nos eletrodos. A posição destes dipolos é utilizada como característica para a classificação, sendo que para gerar os dipolos que representam a atividade interna do cérebro, utiliza-se o algoritmo de análise de componentes independentes (*Independent Component Analysis* – ICA) como etapa de pré-processamento dos sinais. A aplicação do algoritmos ICA sobre um conjunto de sinais gera uma projeção destes sinais sobre um espaço onde as componentes resultantes são estatisticamente independentes.

Para a análise a partir do modelo de dipolos equivalentes, considera-se que cada componente independente gerada pelo algoritmo ICA corresponde à ativação de um determinado dipolo dentro do volume cerebral. Desta forma, pode-se determinar sua localização dentro do volume e utilizar esta informação para a classificação (QIN; DING; HE, 2004; PION-TONACHINI et al., 2015).

Nesta Tese de Doutorado foram utilizadas as características de frequência determinadas através da transformada de Fourier, sendo que a seleção de características é realizada automaticamente utilizando-se a entropia relativa, também chamada de divergência de Kullback–Leibler (*Kullback–Leibler divergence*) que representa uma medida das diferenças entre duas distribuições estatísticas.

Considerando duas distribuições estatísticas discretas P e Q , a divergência de Kullback–Leibler entre P e Q é definida segundo a equação 2.1 (COETZEE, 2005; ZHANG et al., 2013).

$$D(P||Q) = \sum_k P_k \ln \frac{P_k}{Q_k} \quad (2.1)$$

É possível observar que esta medida não é simétrica, ou seja $D(P||Q) \neq D(Q||P)$, então, uma nova medida de divergência simétrica de Kullback–Leibler $J(P||Q)$ pode ser

definida segundo a equação 2.2.

$$J(P||Q) = \sum_k P_k \log \frac{P_k}{Q_k} + \sum_k Q_k \log \frac{Q_k}{P_k} \quad (2.2)$$

A divergência simétrica, assim definida, é não negativa e simétrica, e é comumente utilizada para auxiliar na identificação de características para classificadores (COETZEE, 2005; KULLBACK; LEIBLER, 1951; BENEVIDES; BASTOS FILHO, 2012; BUENO; BASTOS FILHO, 2015b). Para a seleção de características, suas distribuições devem ser comparadas duas a duas para cada tarefa, e os conjuntos que apresentam um valor maior que um determinado limite são então utilizados como características para classificação (COETZEE, 2005; ZHANG et al., 2013).

2.5.3 Algoritmos de classificação

A etapa de classificação consiste em associar as características calculadas anteriormente, a partir dos sinais EEG, a uma determinada classe, a qual pode corresponder a um estado mental específico.

Entre os algoritmos de classificação mais comumente usados na bibliografia estão os classificadores lineares, por sua simplicidade estrutural e pelos bons resultados na classificação binária entre duas classes. Quando se faz necessária a classificação entre mais de duas classes, os classificadores não lineares apresentam melhores resultados que os lineares (FABIANI et al., 2004; NICOLAS-ALONSO; GOMEZ-GIL, 2012; HENDEL; BENYETTOU; HENDEL, 2016).

2.5.3.1 Modelos ocultos de Markov

Os classificadores baseados nos modelos ocultos de Markov (*Hidden Markov Models* – HMM), utilizados principalmente em sistemas de reconhecimento automático de voz, também podem ser utilizados para a classificação de estados mentais associados a ICCs.

Alguns trabalhos apresentam classificadores baseados em HMM como alternativa de classificador para sistemas com múltiplos estados mentais em uma ICC (OBERMAIER; MÜLLER; PFURTSCHELLER, 2003; OBERMAIER, 2001; OBERMAIER et al., 2001; BASHASHATI; FATOURECHI; WARD, 2007). Os modelos de Markov como classificadores se baseiam na geração de diferentes cadeias, e na verificação de qual destas cadeias tem a maior probabilidade de haver gerado a sequência de características apresentadas. A Figura 16 ilustra a estrutura de um modelo oculto de Markov. O modelo gera saídas com uma determinada probabilidade, partindo de uma entrada com uma probabilidade definida.

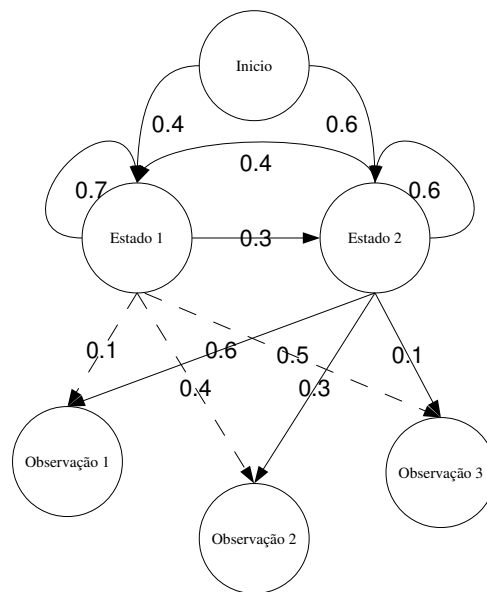


Figura 16 – Representação de um modelo oculto de Markov (HMM). Os estados representados não são visíveis ao observador. As observações permitem a inferência dos estados, conhecidas as probabilidades representadas na figura. Figura do autor.

Se uma sequência de valores é observada na saída do modelo, pode-se determinar a sequência dos estados internos, ocultos, a partir das probabilidades de transição e de emissão. A probabilidade de transição é a probabilidade de ocorrência de um próximo estado a partir de um estado atual, e a probabilidade de emissão é a probabilidade de que uma observação seja gerada a partir do estado atual.

O classificador pode resolver o problema seguindo dois caminhos diferentes: um é o caminho direto, partindo do primeiro estado até a observação, e o segundo caminho parte da observação e tenta chegar ao primeiro estado através dos estados ocultos. Este algoritmo é denominado algoritmo de Viterbi (BILMES, 2002), e ambos os caminhos são similares, mas apresentam condições de otimização próprias.

O número de referências ao uso do algoritmo HMM é muito maior em sistemas de reconhecimento de voz que em sistemas de ICCs (BIAGETTI et al., 2016). Em sistemas de reconhecimento de voz, pode-se implementar o classificador ao nível de caracteres ou ao nível de palavras, dependendo da estrutura utilizada. Em (RABINER, 1989), o autor apresenta a estrutura dos modelos de Markov e os algoritmos, tanto para a implementação direta quanto com o algoritmo de Viterbi.

Apesar de alguns autores apresentarem os classificadores baseados em HMM como alternativa para a implementação de ICCs de múltiplas classes, esta arquitetura não foi utilizada nesta Tese de Doutorado pois decidiu-se implementar os classificadores baseados em redes neurais auto organizadas (CHIAPPA; BENGIO, 2004; OBERMAIER, 2001; OBERMAIER; MÜLLER; PFURTSCHELLER, 2003; BASHASHATI; FATOURECHI; WARD, 2007; NASEHI; POURGHASSEM, 2013).

2.5.3.2 Redes neurais artificiais

As redes neurais artificiais (RNA) são algoritmos bioinspirados que imitam o funcionamento de algumas estruturas nervosas encontradas em animais e seres humanos (KOHONEN, 2001). As redes neurais artificiais possuem a estrutura de um neurônio do sistema nervoso conectado a neurônios vizinhos, onde cada neurônio possui um conjunto de coeficientes que se comportam como as sinapses dos neurônios, e estes coeficientes são ajustados no processo de treinamento da rede neural. Após o treinamento, a rede pode identificar padrões que se assemelham aos padrões apresentados durante o treinamento (AMATO et al., 2013).

Entre as redes neurais estudadas estão as redes *perceptron* multicamada (*Multi Layer Perceptron* – MLP), as quais possuem um comportamento similar aos neurônios do sistema nervoso periférico; o mapa auto-organizado (*Self Organizing Map* – SOM) ou rede de Kohonen (KOHONEN, 2001), que possui um comportamento similar ao dos neurônios do sistema nervoso central; e as redes *Learning Vector Quantization*–LVQ, que combinam as características das duas redes citadas anteriormente, sem que ela seja uma fusão das duas anteriores.

As redes neurais *perceptron* foram desenvolvidas a partir do modelo dos neurônios do sistema nervoso periférico, tais como apresentados nas equações 2.3 e 2.4. Com o agrupamento destas estruturas neuronais, chegaram-se às redes neurais no final da década de 1950 e, no início dos anos 1960, elas começaram a ser utilizadas para a resolução de problemas (GLUCK; MYERS, 2000). Estes modelos consideram alguns aspectos fisiológicos do funcionamento dos neurônios, como citado na seção 2.1.2. Sendo que a integração dos diferentes potenciais para a geração de um impulso nervoso ocorre no corpo do neurônio, e as conexões entre os neurônios podem ser mais ou menos reforçadas por um processo de aprendizagem ou memorização através do ajuste dos coeficientes que representam as sinapses.

No modelo matemático de um neurônio, ou neurônio artificial, os dendritos são representados pelas distintas entradas, e as sinapses são modeladas por um conjunto de pesos associados a cada uma das entradas. A integração das diferentes entradas é realizada pela soma das componentes de entrada, ponderada pelos pesos das entradas, gerando uma saída a partir de uma função de ativação.

De acordo com as características dos neurônios reais, os neurônios artificiais podem ser modelados de acordo com a equação 2.3.

$$y = f(\sum_i a_i \cdot u_i), \quad (2.3)$$

onde u_i são as entradas do neurônio, a_i são os pesos de cada uma das entradas do neurônio,

e $f(U)$ é uma função do tipo:

$$f(U) = \begin{cases} 0, & \text{si } U < \epsilon \\ \alpha, & \text{si } U > \epsilon, \end{cases} \quad (2.4)$$

com α representando o potencial do impulso nervoso de saída, e ϵ o limite característico da célula.

Nas Figuras 1 e 17 estão representadas as estruturas de um neurônio real e de um neurônio artificial, respectivamente.




Figura 17 – Representação da estrutura de um neurônio artificial. Figura do autor.

Os neurônios artificiais podem conectar-se, formando uma rede similar às redes formadas por neurônios reais. Os primeiros desenvolvimentos de redes neurais para a resolução de problemas de engenharia e processamento de sinais estão associados aos trabalhos de Bernard Widrow e Ted Hoff entre o final dos anos 1950 e início dos anos 1960 (GLUCK; MYERS, 2000; WIDROW; HOFF, 1960). Um neurônio artificial isolado é capaz de resolver problemas de classificação linear, entretanto, para a resolução de problemas não lineares, é necessário a utilização de mais neurônios e de mais camadas sobrepostas, gerando uma estrutura mais complexa, porém com a capacidade de resolver problemas mais complexos e não lineares, com o treinamento adequado.

Os métodos de treinamento diferem para diferentes tipos de RNA, mas consistem em processos iterativos para a determinação dos pesos internos da rede (HAGAN et al., 2014). Para redes MLP, durante o processo de treinamento, as entradas são apresentadas à rede, e uma saída é calculada, a qual é então comparada à saída desejada, e o erro resultante desta comparação é propagado para os pesos internos da rede (HAGAN et al., 2014). Desta forma, a rede tem seus pesos ajustados tentando-se minimizar o erro entre a saída e o valor desejado. O treinamento é interrompido respeitando-se algumas situações, tais como: um erro mínimo, onde a saída da rede já é próxima o suficiente da saída real; um gradiente mínimo de saída, caso a saída convirja para um determinado valor, diferente do valor desejado; ou um número de repetições, caso a saída da rede não se aproxime da saída real e não convirja para outro valor de saída (HAGAN et al., 2014).

Uma rede corretamente treinada pode generalizar um determinado problema se as características de entrada e o número de iterações da etapa de treinamento forem bem escolhidos (HAGAN et al., 2014). Redes muito treinadas em um conjunto de dados tendem

a se especializar, gerando um efeito de sobre-treinamento, onde a rede cria uma tendência de somente reconhecer os valores apresentados durante o treinamento. Por outro lado, se as características escolhidas não caracterizam bem o processo, a rede pode reconhecer outros processos não relacionados ao processo desejado (HAGAN et al., 2014; NICOLAS-ALONSO; GOMEZ-GIL, 2012; MCFARLAND; SARNACKI; WOLPAW, 2011).

As redes de Kohonen possuem um funcionamento semelhante ao dos neurônios do córtex cerebral, diferentemente das redes MLP (KOHONEN, 2001; HAGAN et al., 2014), nos quais estes neurônios estão organizados de maneira que podem se agrupar e formar conjuntos que se ativam para entradas similares. Por exemplo, ao observar a disposição somatotópica do córtex cerebral mostrado na Figura 7, percebe-se que existe uma certa continuidade na disposição das regiões do cérebro relacionadas às regiões do corpo, tanto no sistema de controle motor como no sensorial.

Esta organização do cérebro levou ao desenvolvimento deste tipo de redes, também chamadas de mapa auto-organizado (Self Organizing Maps – SOM) (KOHONEN, 2001; HAGAN et al., 2014). Neste tipo de rede, o treinamento é realizado medindo-se a ativação dos neurônios para uma determinada entrada e ajustando os seus coeficientes para que os neurônios mais ativos com uma determinada entrada estejam em regiões próximas, de maneira não supervisionada, uma vez que o mapa final não é conhecido até o final do processo de treinamento (KOHONEN, 2001; HAGAN et al., 2014). O grande desafio ao utilizar os mapas auto-organizados está na interpretação das ativações dos mesmos para identificar a classe desejada. Assim, esta Tese de Doutorado se dedica a investigar formas de associar a informação contida na rede SOM a um conjunto de saídas que representam as atividades mentais.

A Figura 18 representa a evolução do treinamento de uma rede SOM bidimensional com 64 neurônios, a título de exemplo. Neste exemplo, podem-se observar os dados apresentados à rede como os círculos nos gráficos. Na Figura 18 (a) é apresentada a distribuição dos coeficientes de todos os neurônios no início do treinamento, onde estes estão uniformemente distribuídos sobre o espaço das características. À medida que as amostras vão sendo apresentadas aos neurônios da rede, estes tentam se adequar à distribuição dos valores de entrada, formando uma estrutura que se assemelha à distribuição das características à medida que o número de repetições do treinamento avança, o que pode ser observado nas Figuras 18 (b) até 18 (d).

Diferentemente das redes *perceptron*, este tipo de rede não necessita de conhecimento *a priori* das classes às quais pertencem as entradas. No processo de treinamento, o algoritmo busca encontrar similaridades entre as amostras e os neurônios, gerando neurônios que se aproximam dos padrões presentes nas amostras de entrada. Este agrupamento de amostras ao redor dos neurônios utiliza uma medida predefinida, a qual pode ser calculada de diferentes maneiras; tais como distância euclidiana ou produto interno, calculados

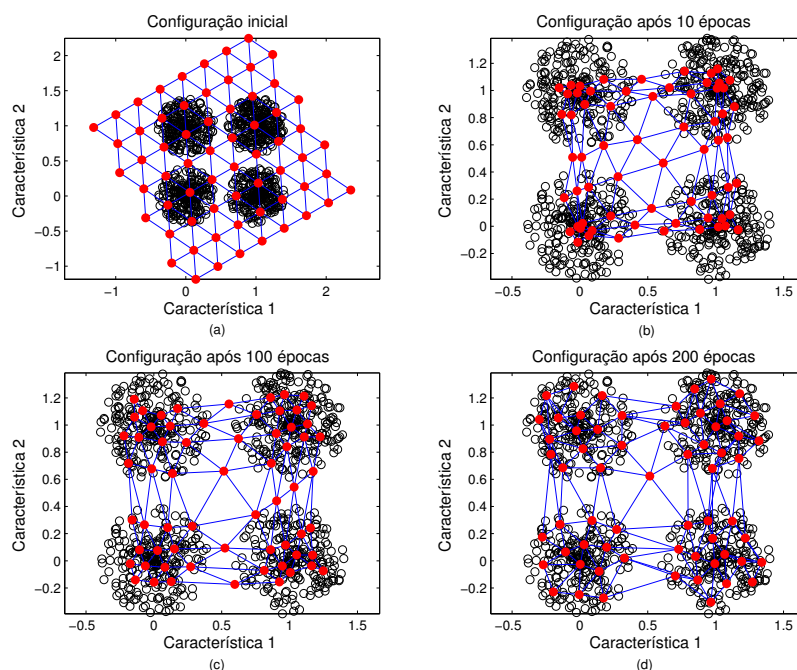


Figura 18 – Evolução do treinamento de uma rede SOM para uma série de dados aleatórios gerados para exemplificar o funcionamento da rede. Pode-se observar que a rede aproxima a distribuição dos dados utilizados para o treinamento. Figuras do autor.

entre o vetor de características da entrada e o vetor de coeficientes no neurônio.

O treinamento neste tipo de rede está baseado na apresentação de uma amostra de dados à rede e a consequente identificação do neurônio com a maior ativação, sendo que este neurônio tenta aproximar os seus vizinhos aos seus valores para que entradas similares se aproximem dele. Como os neurônios vizinhos são ativados por sinais próximos, acaba-se formando uma região que se ativa para entradas similares.

Para a sua utilização como classificador, deve-se apresentar à rede características rotuladas e criar um mapa de rótulos para a sua ativação, de modo que a saída desta possa ser interpretada como a classe dos dados classificados.

Uma das principais aplicações para as redes SOM é a visualização de dados multidimensionais (HAGAN et al., 2014; KOHONEN, 2001). Nesta aplicação, a utilização da rede SOM apresenta vantagens, uma vez que a saída da rede representa uma distribuição de amostras em gráficos bi ou tridimensionais, sendo mais fácil verificar as relações entre os grupos de amostras, principalmente para o caso de sinais multidimensionais.

As redes SOM podem ser construídas com um número arbitrário de dimensões, porém, para manter a característica de visualização da estrutura dos dados, recomenda-se o uso de mapas de 2 ou 3 dimensões (HAGAN et al., 2014; KOHONEN, 2001). O princípio de funcionamento das redes SOM é bastante similar ao utilizado nas redes denominadas *Learning Vector Quantization* – LVQ. Nestas últimas, porém, uma rede competitiva de

entrada gera subclasses que são classificadas utilizando uma estrutura similar a uma rede MLP para gerar as saídas classificadas (HAGAN et al., 2014; KOHONEN, 2001). O treinamento de uma rede LVQ, por outro lado, é supervisionado, necessitando assim de dados rotulados de acordo com as classes. Ao utilizar as redes SOM como base para um classificador, pode-se observar claramente a variabilidade das características das amostras apresentadas ao classificador. No caso das características presentes em uma mesma classe, pode-se observar uma certa dispersão nas ativações que, em certas situações, chega a invadir a região característica de outra classe. Esta variabilidade deve ser condicionada pela etapa de identificação dos grupos no momento de gerar as saídas classificadas.

2.5.3.3 Métodos estatísticos aplicados às características dos sinais

Um dos métodos estatísticos aplicados às características dos sinais é o método dos padrões espaciais comuns (Common Spatial Patterns – CSP) que procura projetar a informação contida em um conjunto de dados em um pequeno número de padrões que oferecem informação a respeito da disposição espacial dos valores em um conjunto reduzido de características que servem para discriminar os sinais de entrada entre duas classes (MÜLLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999; ALONSO; VELLASCO, 2016; MCFARLAND; SARNACKI; WOLPAW, 2015).

Entretanto, uma limitação intrínseca deste método é que este está projetado para discriminar uma entre duas classes. Matematicamente, o método se baseia na diagonalização simultânea de duas matrizes de covariância dos dados das classes a serem identificadas, sendo que esta matriz é utilizada para a projeção dos dados do espaço original a um novo espaço onde a variância é projetada para a primeira ou a última linha dos dados no espaço de saída. Desta forma, podem-se classificar os dados de acordo com a variância projetada nos dados de saída.

Como classificador, foi testado nesta Tese de Doutorado o algoritmo CSP, entretanto, por suas características de discriminação entre apenas duas classes, não foi possível implementar este classificador no sistema. Foi também testada a utilização do algoritmo CSP em duas etapas, sendo uma delas identificando se a atividade mental correspondia a uma intenção motora ou cognitiva, buscando identificar a tarefa cognitiva, e uma segunda etapa que seria executada caso a atividade identificada fosse uma atividade motora. Esta segunda etapa buscava identificar, entre as atividades motoras, qual tarefa estava sendo executada. Apesar de imaginarmos que este seria um método viável, os resultados dos testes preliminares foram pouco confiáveis, já que como este algoritmo utiliza a variância e a distribuição dos sinais para separar as classes, o mesmo não foi capaz de discriminar entre as duas classes de movimentos imaginados, pois ambos possuem variâncias similares, apesar de possuírem distribuições diferentes. Assim, os resultados não foram satisfatórios, como era esperado, pois por levar em consideração a variância dos sinais, este algoritmo é

muito suscetível ao ruído presente nos sinais, sendo que o baixo desempenho do algoritmo nos experimentos pode ser devidos à variância do ruído nos sinais. Além da influência do ruído, o algoritmo também tem seu desempenho prejudicado quando é utilizado um número pequeno de dados de treinamento (MCFARLAND; SARNACKI; WOLPAW, 2015; WANG; DENG; HE, 2004; ALONSO; VELLASCO, 2016).

2.5.4 Trabalhos de referência de grupos da área de ICCs

A seguir se apresentam alguns trabalhos de referência em ICCs de alguns centros de pesquisa importantes da área.

Na Universidade Tecnológica de Graz (Áustria) está localizado o *Graz Brain Computer Interface Laboratory* pertencente ao *Institute of Neural Engineering*¹, que é um dos grupos mais relevantes no âmbito das ICCs com pesquisas na área há mais de 20 anos. O grupo de pesquisa de Graz possui uma grande quantidade de contribuições em diferentes áreas, onde se estudam características dos sinais de diferentes origens (STEYRL; KOBLER; MÜLLER-PUTZ, 2016), tecnologias utilizadas para aquisição (PINEGGER et al., 2016) e diferentes técnicas de extração de características e classificação (PFURTSCHELLER et al., 2000; OBERMAIER; MÜLLER; PFURTSCHELLER, 2003; MÜLLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999; SCHERER et al., 2015; SCHWARZ et al., 2015; MÜLLER-PUTZ et al., 2010). Além disso, o grupo organiza regularmente a *Graz BCI Conference*, com a última edição no ano corrente (2017).

O grupo de pesquisa em sistemas para comunicação aberta do Instituto Fraunhofer – Berlim (*Fraunhofer Institute for Open Communication Systems – FOKUS*), em conjunto com o Instituto de Tecnologia de Berlim (*Berlin Institute of Technology*)², são responsáveis pelo projeto *Berlin Brain Computer Interface – BBCE*³, no qual se pretende incentivar o desenvolvimento de novas ICCs. Este grupo organizou nos anos 2002, 2003, 2005 e 2008 uma competição entre os grupos de pesquisa, denominado *BCI Competition*, onde conjuntos de dados foram disponibilizados e os participantes deveriam utilizar seus algoritmos nestes conjuntos de dados. Os resultados foram compilados em artigos e publicados como anais da competição. Os projetos do grupo BBCE utilizam diferentes algoritmos de processamento de dados, como CSP ou identificação de potenciais lentos (*Slow Cortical Potentials – SCP*), entre outros. Em algumas das suas publicações o grupo apresenta resultados da combinação de diferentes características, tais como SCP, dessincronização associada a eventos (*Event Related Desynchronization – ERD*), potenciais de intenção de movimento e potenciais relacionados ao movimento em diferentes partes do córtex motor, além de uma expansão do algoritmo CSP para mais classes, com o fim de aumentar a taxa de transmissão de informação do sistema (DORNHEGE; BLANKERTZ;

¹ <https://www.tugraz.at/institute/ine/home/>

² <http://www.tu-berlin.de/>

³ <http://www.bbci.de/>

CURIO, 2003; DORNHEGE et al., 2004a; DORNHEGE et al., 2004b; ACQUALAGNA et al., 2016; BLANKERTZ et al., 2016; SCHULTZE-KRAFT et al., 2016). Nos últimos anos o grupo organiza *Workshops* sobre o tema, sendo o último organizado em 2015.

O grupo de neurociência do Centro Wadsworth⁴, em Nova York, desenvolve ICCs desde a década de 1990 e possui publicações utilizando diferentes características dos sinais e sistemas de ICCs (WOLPAW et al., 2002; WOLPAW; BIRBAUMER, 2006; WOLPAW et al., 2000; FABIANI et al., 2004; MCFARLAND et al., 2005; KRUSIENSKI et al., 2005; BUNDY et al., 2017; MCFARLAND; SARNACKI; WOLPAW, 2015; MCFARLAND, 2015; MCCANE et al., 2015).

O Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo possui uma linha de pesquisa sobre ICCs, havendo desenvolvido várias aplicações, tais como o controle de cadeiras de rodas utilizando diferentes características do sinal de EEG, tais como a variação de energia da banda alfa (ERD/ERS) (FERREIRA, 2008), SSVEP (MÜLLER, 2012), também usado para controle de veículo autônomo (CASTILLO, 2014), controle de robô de telepresença (FLORIANO et al., 2015; FLORIANO, 2016), e controle de menu de comunicação alternativa (FERRARA, 2015), além também de outros trabalhos do grupo relacionados a SSVEP (COTRINA et al., 2014; TELLO et al., 2015) e o desenvolvimento de técnicas avançadas de classificação de sinais de EEG (BENEVIDES; BASTOS FILHO, 2012),

2.6 Discussão do Capítulo

Neste capítulo foram revisadas as técnicas existentes na literatura ao longo da elaboração do estado da arte sobre sinais EEG e ICCs. Alguns dos algoritmos estudados foram os algoritmos de projeção de dados entre espaços de diferentes dimensões, os quais procuram representar os dados adquiridos em um espaço diferente, mantendo, em alguma medida, a informação contida nos dados originais. No algoritmo PCA, por exemplo, parte da informação é perdida, porém, procura-se manter o máximo possível de informação e reduzir as dimensões para simplificar o tratamento dos dados em etapas posteriores. No algoritmo ICA, a proposta é gerar um conjunto de dados estatisticamente independente capaz de reconstruir os dados originais. A redução das dimensões, neste caso, deve ser realizada pela seleção das características de maneira conveniente.

Outro algoritmo baseado em matrizes de projeção é o CSP, o qual procura acumular a energia dos sinais em uma matriz de saída seguindo uma direção determinada, de acordo com a classe dos dados apresentados.

As redes neurais artificiais são amplamente utilizadas na literatura como classificadores, principalmente as redes de arquitetura MLP. As redes SOM são mais utilizadas

⁴ <https://www.wadsworth.org/research/areas/neurotech>

para a representação bidimensional de distribuições de dados multidimensionais, sendo também utilizadas como camada de entrada de redes neurais LVQ.

A literatura estudada utiliza sistemas de processamento de sinais baseados em computadores pessoais, onde se pode, virtualmente, aplicar quaisquer dos algoritmos aqui apresentados sem grandes limitações com relação ao tempo necessário para o processamento *on line* dos dados. Caso seja necessário, poderia-se inclusive executar mais de um dos algoritmos simultaneamente. Assim, no Capítulo 3 são apresentados os requisitos para o desenvolvimento de um sistema de aquisição de sinais EEG utilizando inicialmente uma plataforma baseada em equipamentos clínicos e computadores pessoais, sendo também feita uma discussão sobre a aplicação dos algoritmos aqui apresentados.

3 Desenvolvimento de um sistema de aquisição de sinais EEG

Neste capítulo é apresentado o desenvolvimento de um sistema de aquisição de sinais EEG, desde o ponto de vista conceitual e de funcionalidades desejadas para o sistema. Neste capítulo também se apresenta o desenvolvimento do software para este sistema.

Na seção 3.1 são descritos alguns experimentos encontrados na literatura. Nesta mesma seção se apresenta uma análise destes experimentos no contexto dos objetivos desta Tese de Doutorado.

Na seção 3.2 se apresenta a proposta conceitual dos experimentos realizados neste trabalho, o qual envolve todos os aspectos das tarefas a serem implementadas no sistema. Nesta seção se apresenta também a justificativa para a escolha destes experimentos, além dos requisitos de segurança do sistema.

Ao final se apresenta o sistema desenvolvido baseado em um dispositivo clínico e um computador pessoal.

3.1 Análise dos experimentos da literatura e desenvolvimento de um modelo experimental

Para a realização dos experimentos desta pesquisa, contou-se com os equipamentos disponíveis no NTA/UFES, para a aquisição e processamento de sinais EEG, os quais serão descritos com mais detalhes na seção 3.3. Os experimentos realizados utilizam tarefas mentais de imaginação de movimento dos membros, além de uma tarefa cognitiva não relacionada a eventos motores. Esta seleção se baseou no estudo de outros trabalhos semelhantes que serão apresentados a seguir.

3.1.1 Graz BCI

Foram estudadas diferentes ICCs para identificar a estrutura dos diferentes sistemas de aquisição e dos experimentos realizados. Entre as estruturas estudadas estão as propostas da Universidade Técnica de Graz (PFURTSCHELLER et al., 2000; LEEB et al., 2006; MÜLLER-PUTZ et al., 2010; SCHERER et al., 2015) que utiliza a apresentação de uma sequência de eventos em tempos predeterminados ao sujeito participante do experimento. Os estímulos são auditivos e visuais, sendo que o estímulo visual representa

qual tarefa deve ser realizada pelo sujeito. Este paradigma está representado na Figura 19, considerando que o sujeito deve responder ao estímulo visual com a imaginação de um movimento de braços ou pernas. A fase inicial deste experimento não é utilizada para a classificação, servindo apenas como uma preparação para o experimento.




Figura 19 – Esquema representativo do diagrama de tempos para o protocolo de experimentos da Universidade Técnica de Graz (Graz BCI). Figura do autor.

Neste procedimento, a extração de características e classificação das mesmas é realizada após a retirada do estímulo visual, sendo, portanto, um processo de classificação baseado na interpretação da resposta do sujeito à apresentação do estímulo. Nos experimentos com realimentação, depois da retirada do estímulo, os dados classificados são apresentados ao sujeito seguindo a estrutura do estímulo inicial para que o sujeito possa adaptar-se ao sistema durante a execução da tarefa. Este sistema pode interpretar e classificar uma saída correta entre duas possibilidades, uma vez que após a retirada do estímulo, o sujeito deve concentrar-se em apenas uma entre duas possíveis tarefas mentais.

3.1.2 Berlin BCI

Outro paradigma estudado foi o do Berlin Brain Computer Interface (BBCI), no qual o sujeito pressiona teclas em um teclado de computador seguindo uma dada sequência em um ritmo definido pelo próprio sujeito (BLANKERTZ et al., 2003; KREPKE et al., 2007; BLANKERTZ et al., 2016; SCHULTZE-KRAFT et al., 2016). A proposta do sistema é a de identificar, através dos dados adquiridos, a tecla a ser pressionada antes que o movimento seja executado. A identificação da mão usada para pressionar a tecla é apresentada ao sujeito como forma de realimentação.

Este paradigma é útil para a identificação de potenciais relacionados a erros na região frontal do cérebro, próximo ao eletrodo Cz, pois sempre que uma tecla é erroneamente pressionada, este potencial ocorre e pode ser identificado, mesmo antes da ativação do sinal mioelétrico (EMG) que caracteriza a ação muscular.

Esta ideia não foi utilizada neste trabalho, pois necessita a realização de movimentos por parte do sujeito durante a etapa de treinamento.

3.1.3 O paradigma de Potenciais Evocados Visuais de Regime Permanente (SSVEP)

Outro paradigma síncrono estudado é o que utiliza os Potenciais Evocados Visuais de Regime Permanente (SSVEP) para a identificação de intenções do sujeito, o qual foi apresentado na seção 2.2. Este paradigma requer a estimulação do sujeito com luzes piscantes de diferentes frequências (ATENCIO, 2015; TELLO, 2016) ou padrões oscilantes com diferentes frequências (FLORIANO, 2016; MÜLLER, 2012).

3.1.4 O paradigma P300

Outro paradigma estudado foi o que utiliza o potencial P300 para a identificação das intenções do sujeito. O potencial P300, citado na seção 2.3.1, pode ser utilizado como característica de entrada para classificadores baseados em potenciais evocados, como citado na seção 2.2. Neste paradigma, são apresentados estímulos ao sujeito e, de acordo com a resposta do sujeito, a entrada apresentada é considerada válida ou não (DORNHEGE, 2006; NICOLAS-ALONSO; GOMEZ-GIL, 2012; ITURRATE et al., 2009; CAPATI; BECHELLI; CASTRO, 2016; MCCANE et al., 2015; WOLPAW et al., 2002; MCFARLAND; SARNACKI; WOLPAW, 2011).

Este tipo de interface é do tipo síncrona, assim como as apresentadas anteriormente, pois depende da apresentação de um estímulo ao sujeito durante a execução da tarefa, o que pode ser cansativo para os usuários. Como fatores como a falta de motivação, a frustração e a fadiga podem afetar negativamente o desempenho das ICCs (ITURRATE et al., 2009; SILVA-SAUER et al., 2013), devem-se avaliar estas situações durante a execução das tarefas e realizar pausas durante as mesmas.

3.1.5 O paradigma assíncrono

Um paradigma assíncrono foi escolhido nesta Tese de Doutorado, o qual não necessita de intervenção ou estímulo do sistema antes da execução da tarefa mental por parte do sujeito (CHIAPPA; BARBER, 2005; CHIAPPA; BENGIO, 2004; BASHASHATI; WARD; BIRCH, 2005; GALÁN; OLIVA; GUÀRDIA, 2007; NICOLAS-ALONSO; GOMEZ-GIL, 2012; SCHERER et al., 2015).

Este paradigma é considerado mais natural e menos cansativo para o sujeito devido à ausência de estímulos visuais constantes. Vale resaltar que outras abordagens híbridas estão sendo estudadas, onde se mesclam características assíncronas e síncronas (COTRINA et al., 2014; CAPATI; BECHELLI; CASTRO, 2016; CASTILLO, 2014). Neste caso, uma ICC assíncrona monitora uma característica espontânea do sujeito, e quando esta característica é identificada, uma ICC baseada em SSVEP é acionada para identificar a real intenção do sujeito.

3.1.6 Procedimentos adotados para as tarefas inicialmente realizadas

Escolheu-se um paradigma baseado na imaginação de movimentos dos membros superiores e uma tarefa cognitiva como tarefas mentais a serem classificadas. Nos experimentos iniciais utilizou-se um conjunto grande de tarefas mentais e entre elas foram definidas as três tarefas, especificadas na seção 3.2.1, que seriam utilizadas na implementação final.

O sistema de aquisição adotado na etapa inicial deste trabalho utiliza uma estrutura de tempos e de estímulos muito similar ao apresentado na Figura 19, embora apenas na etapa de treinamento. A diferença entre esta estrutura e a estrutura utilizada na Universidade Técnica de Graz é a supressão do estímulo sonoro que precede a apresentação do estímulo visual, e a duração de cada uma das etapas da tarefa.

Durante o treinamento, o participante é instruído a não realizar nenhum movimento para não contaminar o sinal com informação sensorial aferente, pois são regiões próximas no cérebro que comandam os movimentos e processam as informações sensoriais. Além disso, sinais mioelétricos (EMG) também podem contaminar o sinal cerebral.




Figura 20 – Estrutura da tarefa implementada para o sistema de aquisição. Figura do autor.

Esta estrutura foi escolhida por apresentar um estado inicial com atividades mentais não motoras, que chamaremos de estado de “inatividade”, anterior à apresentação do estímulo em cada uma das repetições da tarefa.

Na estrutura de Graz, a tarefa tem um tempo total médio de 8 segundos, variando entre um experimento e outro de forma aleatória. Já nos experimentos iniciais realizados nesta pesquisa de doutorado, o tempo de tarefa utilizado foi de 10 segundos para cada experimento. O sistema de aquisição criado é flexível, de forma que se podem modificar estes tempos criando tarefas mais longas ou mais curtas, caso seja necessário.

Na Figura 20 podem-se observar os tempos de apresentação e retirada de estímulos. O sujeito participante é instruído a concentrar-se na tela e executar a tarefa cognitiva. No instante em que se apresenta a indicação da tarefa a ser realizada, o sujeito deve se preparar e, após a retirada do estímulo, iniciar a tarefa mental indicada. Esta tarefa é a imaginação de um movimento ou uma tarefa cognitiva, sendo que os voluntários são

instruídos a imaginar o movimento de maneira não visual, ou seja, como se não estivessem vendo seus membros.

Este paradigma foi utilizado apenas nos experimentos iniciais para validar os sistemas de captura de dados. Após esta etapa passou-se a um paradigma de um sistema assíncrono, onde o mesmo deve identificar os estados mentais do sujeito independentemente de estímulos externos. Desta forma, os experimentos destinados a adquirir dados para o treinamento inicial do sistema devem apresentar informação ao sujeito, porém, durante o funcionamento, o sistema não deve interagir com o sujeito na forma de estímulos.

3.2 Proposta conceitual de requisitos de um sistema de captura de sinais EEG

Esta seção se inicia com a justificativa fisiológica dos experimentos. Esta justificativa está baseada na análise da literatura e na análise dos dados recolhidos e analisados durante a realização dos experimentos iniciais. Em seguida, são apresentados os requisitos de segurança elétrica mínimos para os sistemas de aquisição de sinais cerebrais que devem ser seguidos para que os experimentos possam ser conduzidos com segurança para o sujeito.

3.2.1 Justificativa fisiológica dos experimentos

O paradigma inicial de experimentação apresentado anteriormente possui três estados mentais distintos em todas as tarefas, os quais são utilizados para treinar os classificadores de forma a identificar as diferenças entre cada um dos três, em um estudo *off-line*. Os estados são os seguintes:

- *Inatividade ou cognitivo*: o estado de inatividade é o estado em que o sujeito inicia a realização da atividade, sendo que o sujeito recebe instruções para que relaxe e imagine uma tarefa cognitiva, não motora, tal como pronunciar mentalmente palavras, ou realizar mentalmente cálculos matemáticos, utilizando sempre a mesma tarefa para todas as repetições do experimento;
- *Apresentação do estímulo*: quando o estímulo é apresentado ao sujeito, este deve identificá-lo e aguardar até que a referência que indica a tarefa desapareça para, então, iniciar a tarefa mental relacionada ao estímulo. Este é um estado curto e caracteriza-se por apresentar grandes mudanças na ativação cerebral, devido à apresentação do estímulo visual e processamento cerebral desta informação;
- *Execução da tarefa*: quando o estímulo visual é retirado, o sujeito deve iniciar a tarefa mental associada ao estímulo apresentado. Neste estado final, o sujeito deve realizar

a tarefa continuamente até que se informe o final desta tarefa. Os movimentos imaginados, neste caso, devem ser cíclicos para que o sujeito possa imaginá-los continuamente, seguidas vezes, até o fim do tempo da tarefa.

Segundo (LEHR JR, 2006), a região occipital é responsável pela percepção e processamento da informação visual, o que implica em mudanças na atividade desta região nos instantes posteriores à modificação dos estímulos visuais. Mudanças nos sinais provenientes dos eletrodos nesta região eram esperados e foram observados durante a apresentação e retirada do estímulo visual ao sujeito. As alterações observadas, apesar de identificáveis, apresentam mudança nos níveis de energia muito inferiores aos observados em operações como abrir e fechar os olhos, os quais geram mudanças muito grandes nos níveis de energia do ritmo alfa. Mudanças na imagem apresentada ao sujeito também geram mudanças nos níveis de energia dos sinais dos eletrodos desta zona, ainda que não tão significativas como as mudanças relacionados com o abrir e fechar dos olhos.

Estas mudanças na energia na banda alfa dos sinais da região occipital são utilizados em uma das ICCs desenvolvidas na Universidade Federal do Espírito Santo (UFES), a qual utiliza essa mudança de energia para identificar uma seleção feita pelo voluntário, funcionando como um botão acionado por sinais de EEG. Nesta ICC da UFES se utiliza um sistema de varredura entre várias opções e, no momento em que o sujeito identifica a opção desejada, uma ação de fechar os olhos é reconhecido pelo sistema como a seleção daquela opção (FERREIRA, 2008). Este sistema possui uma taxa de acerto superior a 98%, mas requer que o usuário possa fechar os olhos de maneira voluntária e consciente no instante adequado, sendo considerada uma ICC dependente.

Ainda segundo (LEHR JR, 2006), a região do lóbulo parietal é responsável pela integração sensorial e pela manipulação de objetos, o que leva a imaginar que mudanças nos sinais destas regiões podem ser influenciados pelas condições de realização dos experimentos. Por outro lado, o lóbulo frontal é o responsável pela consciência, pela memória de longo prazo, emoções, associação de palavras a objetos e à execução de tarefas motoras. Estas associações tornam o lóbulo frontal o mais complexo de todo o cérebro. As regiões envolvidas diretamente com a execução das tarefas motoras estão localizadas na parte anterior do *central sulcus*, na parte posterior do lóbulo frontal, em ambos os hemisférios e localizados contralateralmente, ou seja, as modificações observadas no lóbulo direito refletem-se em movimentos do lado esquerdo do corpo e vice-versa. Uma vez que o lóbulo frontal é também responsável pelas emoções, pode-se, em princípio, monitorar a atividade para identificar a aceitação do sistema por parte do usuário, e utilizar esta informação para melhorar a classificação, ou mesmo para o treinamento do sistema. Algumas publicações, inclusive, já identificam este tipo de informação relacionada às emoções (BUTTFIELD; FERREZ; MILLÁN, 2006; FERREZ; MILLÁN, 2005; KAYSER; TENKE, 2015; BIRBAUMER et al., 2009)

Com as funções básicas de alguns dos lóbulos do cérebro apresentadas, é feita a descrição das premissas às quais se baseiam as tarefas implementadas no sistema desenvolvido nesta Tese de Doutorado. A tarefa inicial se baseia no relaxamento do sujeito ou na execução de uma tarefa mental não relacionada à execução de movimentos. Neste estado, busca-se obter uma série de características próximas umas das outras, com uma certa variabilidade, principalmente nas áreas relacionadas à realização de movimentos. Esta variabilidade é esperada, pois espera-se uma supressão da atividade cerebral na faixa relacionada à banda *alfa* durante a execução do movimento, ou sua imaginação. Na Figura 21 pode-se apreciar a disposição de algumas características ao longo de uma janela de tempo durante a tarefa de inatividade. Também se observa uma certa correlação entre instantes de tempo consecutivos no sinal capturado, a qual pode ser interpretada como uma situação de concentração do usuário na realização da tarefa, como se esperava inicialmente. Esta observação da correlação foi posteriormente utilizada para uma análise dos sinais com vistas à avaliação da contaminação dos dados capturados, a qual é analisada com mais detalhes na seção 4.4.

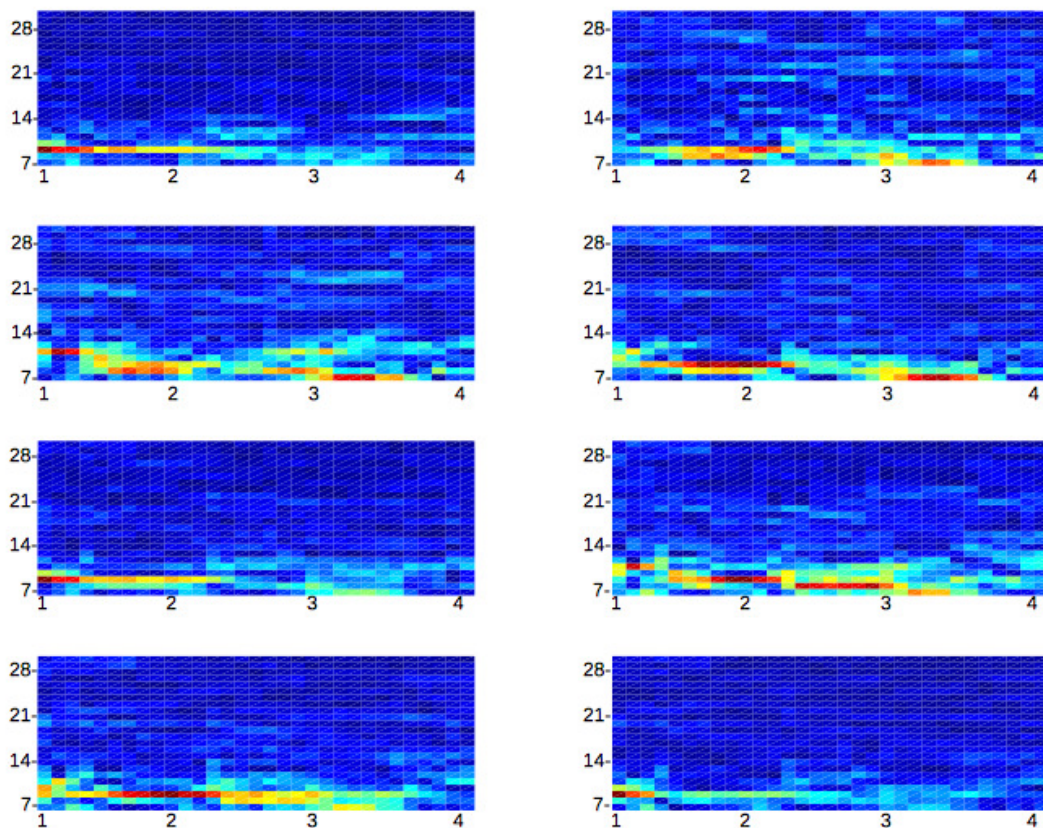


Figura 21 – Representação das características de frequência dos sinais EEG de um voluntário na tarefa de inatividade para os canais utilizados no sistema. No eixo horizontal está representado o tempo entre o segundo 1 e o segundo 4 de uma repetição, representando a tarefa de inatividade. No eixo vertical estão representadas amplitudes das componentes de frequência entre 7 e 31 Hz. A cor azul indica menor amplitude da componente, e a cor vermelha indica maior amplitude da componente. Figuras do autor.

A apresentação do estímulo visual provoca mudanças, principalmente na região do lóbulo occipital nos instantes posteriores à apresentação e retirada do estímulo visual. Como a informação visual muda com a apresentação do estímulo visual, o processamento mental desta informação também muda, e esta mudança pode ser observada nos sinais capturados na região occipital. A apresentação do estímulo também indica ao sujeito que este deve iniciar a tarefa motora em alguns instantes. No instante em que se apresenta o estímulo, o sinal mostra características de frequência ligeiramente modificadas na banda alfa. Além disso, observou-se que a correlação observada entre intervalos de tempo nas características de frequência do sinal é mais baixa durante o tempo em que o estímulo está presente, o que pode ser interpretado no processamento do estímulo e preparação da tarefa motora.

As tarefas de imaginação de movimentos envolvem principalmente as áreas responsáveis pelo controle motor, localizados ao redor do *central sulcus*. Mudanças na atividade observada nestas áreas resultam em características próximas, porém, com uma certa variabilidade e claramente localizadas ao longo do espaço no couro cabeludo. Na Figura 22 se pode observar a lateralização das atividades, de acordo com a tarefa realizada. Observa-se uma diminuição da potência na banda alfa das regiões envolvidas na atividade mental, no momento do início da tarefa. Observou-se uma certa correlação temporal entre as características do sinal, a qual pode ser evidência da concentração do sujeito na execução da tarefa. O estudo da correlação entre as características será apresentado na seção 4.4.




Figura 22 – Representação da atividade dos sinais EEG na tarefa de imaginação de movimentos. O *central sulcus* corresponde ao eixo horizontal no centro da figura. Dados extraídos de um dos experimentos com sujeitos voluntários. A cor azul indica menor amplitude da componente, e a cor vermelha indica maior amplitude da componente. Figura do autor.

A imaginação de movimentos foi considerada como tarefa recomendada para esta

aplicação nos sistemas de controle de interfaces baseados em EEG porque este tipo de tarefa mental representa ações que podem ser traduzidas em respostas similares pelo sistema de controle, o que pode aumentar a aceitação deste por parte dos usuários. Vale ressaltar que a imaginação de movimentos envolve regiões relacionadas aos movimentos reais (PORRO et al., 1996; DECETY, 1996) o que pode tornar mais viável a implementação em pessoas que tenham limitações motoras.

3.2.2 Requisitos de qualidade do sinal

O sinal EEG, como apresentado na seção 2.3, é um sinal de amplitude muito baixa (alguns μV) (MALMIVUO; PLONSEY, 1995) e é formado por uma grande quantidade de fontes de sinal que se somam no tecido volumétrico para formar o sinal final (GLOOR, 1985; SCHWARTZ et al., 2006). Estes sinais provenientes das fontes não relacionadas à tarefa de interesse podem ser traduzidas como ruídos ou artefatos inerentes ao sinal, pois não agregam informação ao sinal. Além desta característica do sinal, o eletrodo também insere artefatos ao sinal devido à interface entre o mesmo e o gel condutor e entre o gel condutor e a pele (HUIGEN; PEPER; GRIMBERGEN, 2002). Este artefato devido ao contato, e depende do tipo de eletrodo utilizado, da preparação da pele, do tempo de preparação do eletrodo e varia com o inverso da frequência, ou seja, este artefato é maior para frequências mais baixas. Em algumas situações este artefato pode inclusive superar o nível dos sinais EEG (HUIGEN; PEPER; GRIMBERGEN, 2002).

3.2.2.1 Equipamento de aquisição de EEG

No Laboratório do Núcleo de Tecnologia Assistiva (NTA) da UFES está disponível um sistema de aquisição de sinais baseado em um amplificador clínico BrainNet BNT36 (Lynx Tecnologia, 2013) que cumpre com todos os requisitos de isolamento elétrica do usuário, e que foi utilizado no desenvolvimento deste trabalho. O sistema utiliza eletrodos passivos aplicados com gel condutor para coletar sinais do sujeito, os quais se conectam ao amplificador através de cabos de aproximadamente 1 m de comprimento.

A melhor solução para a amplificação dos sinais EEG seria a utilização de eletrodos ativos, com a amplificação localizada no próprio eletrodo, porém, esta solução não foi adotada neste trabalho por não estarem disponíveis, e devido ao seu alto custo.

Verificou-se também que a quantidade de ruído no sinal tem uma certa relação com o ambiente onde se realizam os experimentos, devido à quantidade de ruído eletromagnético que pode estar presente no ambiente.

Neste trabalho, também se estudou uma forma de verificar a qualidade do sinal capturado através da correlação entre amostras das características em intervalos de tempo não consecutivos. Observou-se experimentalmente que sinais fortemente contaminados por

ruídos de diferentes fontes apresentam uma baixa correlação, mesmo durante a execução da tarefa, sendo que a correlação aumenta devido à concentração do sujeito, como foi constatado durante os experimentos realizados. Os resultados dos estudos sobre correlação estão listados no Capítulo 4.

3.3 Sistema final desenvolvido

Todos os experimentos desta pesquisa foram realizados com o equipamento de aquisição de EEG comercial (BrainNet BNT36), o qual possui 36 canais, sendo que destes, 32 são canais AC, sendo 22 monopolares dedicados à captura de EEG, 10 canais mono ou bipolares, e mais 4 canais CC. Este sistema pode ser visualizado na Figura 23.



Figura 23 – Equipamento BrainNet BNT36, utilizado nos experimentos no NTA/UFES. Figura retirada da internet(<http://www.lynxtec.com.br/medica.htm>).

Este equipamento clínico possui certificação da ANVISA para ser utilizado no ambiente clínico. O BNT36 é comercializado em conjunto com um programa de interface que realiza a sua configuração, recebe os dados capturados e realiza processamentos simples como aplicação de filtros, além da geração de relatórios e do controle de pacientes. O programa ainda apresenta funções específicas para a aplicação médica à qual se destina.

Esta interface não possui conexão direta nativa com o Matlab, mas pode exportar os dados adquiridos, de forma que o Matlab possa importá-los e se possa trabalhar os mesmos neste ambiente.

O equipamento BNT36 comunica-se com o computador através de uma conexão de rede, utilizando o protocolo *User Datagram Protocol* (UDP), onde os pacotes enviados pela rede devem ser inteiramente processados pela aplicação do usuário. Este protocolo de rede não possui algumas ferramentas de verificação de erros e de garantia de entrega do protocolo *Transfer Controle Protocol* (TCP), mas utiliza menos recursos computacionais,

garantindo uma execução mais rápida do programa de captura dos dados e também a implementação em dispositivos embarcados, como é o caso do processador digital de sinais presente no BNT36.

Como os dados não são criptografados para transmissão, é possível interceptar os pacotes e interpretá-los para recuperar os dados, sem necessidade de utilizar o programa do fabricante. Com este intuito foram desenvolvidas no laboratório algumas ferramentas para este fim. Inicialmente foi desenvolvido um programa capaz de interceptar os pacotes e interpretá-los (BENEVIDES et al., 2014) e também um conjunto de rotinas para o ambiente Matlab capazes de controlar a aquisição e a configuração do BrainNet diretamente. Estas rotinas foram utilizadas para realizar a aquisição dos dados do sistema de interface, sem a necessidade de utilização do programa proprietário durante a captura de dados. O programa proprietário era utilizado somente durante a aplicação dos eletrodos ao sujeito, uma vez que o programa possui uma interface para a visualização da impedância de contato do eletrodo, garantindo desta forma uma melhor relação sinal ruído.

Os eletrodos utilizados para a aquisição dos sinais EEG são os mesmos utilizados em procedimentos clínicos de EEG e devem ser aplicados sobre o couro cabeludo nos pontos específicos que se deseja monitorar, os quais são definidos pelo responsável pelo experimento em posições específicas, ou utilizando algum dos métodos padronizados de posicionamento de eletrodos sobre o couro cabeludo, tal como o sistema 10/20, mostrado na Figura 8. Neste estudo optou-se por utilizar um dos padrões de posicionamento de eletrodos, de forma a permitir o uso destas posições para que se pudesse aproveitar resultados encontrados na bibliografia clínica e de trabalhos de outros grupos de pesquisa no que se refere à análise da atividade EEG com relação à identificação das atividades mentais relacionadas aos diferentes lóbulos do cérebro.

Para simplificar a montagem dos eletrodos, encontram-se disponíveis no mercado toucas ou gorros elásticos com eletrodos que seguem os padrões usados na prática clínica (10/20, 10/10, etc.). Estes gorros com eletrodos oferecem algumas vantagens se comparados aos eletrodos individuais, uma vez que os gorros simplificam a montagem e oferecem uma melhor precisão no posicionamento dos mesmos, desde que se respeitem as regras de colocação do gorro. Como os gorros são elásticos, a distância entre os eletrodos aumenta se a cabeça do sujeito for maior, ajustando automaticamente a distância entre os eletrodos. A Figura 24 apresenta o gorro utilizado para a realização dos experimentos.

Durante os experimentos foram usados gorros com 20 e 64 eletrodos, sendo que foi analisado um subconjunto de 8 eletrodos do padrão 10/20 para a identificação das características para a classificação.

Além do padrão 10/20, existem outros padrões, como os 10/20 estendido ou 10/10, entre outros (OOSTENVELD; PRAAMSTRA, 2001; JURCAK; TSUZUKI; DAN, 2007; RAMADAN; VASILAKOS, 2017). Outros padrões de posicionamento de eletrodos exis-




Figura 24 – Gorro com eletrodos segundo o sistema 10/20 utilizado nos experimentos de aquisição de EEG. Figura do autor.

tem no mercado com números ainda maiores de eletrodos, entre estes podem-se citar os sistemas da empresa Electrical Geodesics, Inc que são compostos por malhas onde se podem conectar 32, 64, 128 ou 256 eletrodos (Electrical Geodesics, 2017a). Estes equipamentos também são utilizados na prática clínica, porém, devido à sua elevada complexidade, dado o grande número de eletrodos, somente são usados em casos muito específicos.

O sistema desenvolvido nesta Tese de Doutorado utiliza o equipamento clínico BrainNet – BNT36 conectado a um computador pessoal responsável por gerenciar os experimentos como meio para adquirir os sinais EEG de um gorro. Os experimentos de treinamento consistem na apresentação de estímulos de referência para orientar o sujeito com relação ao tipo de atividade a ser imaginada, cognitiva ou motora. O computador também processa os dados capturados para gerar as saídas.

O paradigma de implementação final utiliza um paradigma de captura de dados de forma contínua, e uma identificação de tarefa de forma assíncrona. Neste paradigma, durante a operação *on-line*, o sujeito não recebe estímulos, devendo gerar alterações voluntárias para que o sistema possa identificar e criar saídas classificadas com base nessas alterações voluntárias.

Este paradigma pode apresentar dificuldades no que diz respeito ao treinamento do classificador, uma vez que, durante o treinamento, o sujeito recebe estímulos que o guiam durante a coleta de dados, entretanto, a presença do estímulo durante a etapa de treinamento pode gerar alterações na distribuição das componentes de frequência, dificultando o trabalho do classificador.

3.4 Discussão do capítulo

Neste capítulo foram apresentadas algumas das estratégias utilizadas na literatura para aquisição de sinais EEG, com a finalidade de desenvolver a ICC proposta nesta Tese de Doutorado. Baseando-nos nestas estratégias, foi proposta uma metodologia de aquisição de sinais em laboratório. Apresentaram-se também os requisitos de um sistema de captura de sinais EEG, analisando-se o aspecto fisiológico desses sinais. Fez-se também um estudo sobre a qualidade dos sinais envolvidos na análise para desenvolver a ICC deste trabalho. Finalmente, apresentou-se também os paradigmas de experimentação utilizados no desenvolvimento do trabalho, além dos equipamentos utilizados na pesquisa.

4 Discussão sobre algoritmos de processamento, extração de características e classificação

Neste capítulo são apresentados e discutidos os algoritmos estudados ao longo do desenvolvimento desta Tese de Doutorado, seguindo a sequência lógica de pré-processamento, extração de características e classificação. Também se apresenta neste capítulo o algoritmo de validação de dados *on-line* desenvolvido ao longo deste trabalho. Neste capítulo são também apresentadas as discussões a respeito dos algoritmos do sistema desenvolvido e, ao final, uma breve apresentação do sistema final implementado.

4.1 Algoritmos de pré-processamento

Os algoritmos de pré-processamento estudados para aplicações em sinais EEG foram os filtros temporais para limitação de banda dos sinais, os filtros espaciais para a aplicação nos dados capturados, e os algoritmos de projeção de dados como PCA e ICA, descritos na seção 2.5.1.

Os filtros digitais são algoritmos de processamento de sinais muito utilizados para a adequação dos sinais às bandas de frequência da aplicação final. Nesta aplicação os filtros foram utilizados para ajustar os sinais capturados pelo BNT36 à aplicação na ICC, já que os sinais adquiridos diretamente do BNT36 não são filtrados pelo hardware do mesmo para a banda de interesse, possuindo uma largura de banda superior à necessária para a aplicação.

Os filtros espaciais apresentados na seção 2.5.1 foram estudados como uma maneira de diminuir a influência, principalmente, dos sinais gerados pela atividade de outras partes do cérebro que são comuns a mais canais. Este processamento possui um papel importante para a extração das características, pois aumenta a relação sinal ruído das características que se procuram identificar (ALONSO; VELLASCO, 2016; MCFARLAND, 2015).

Ressalte-se que, como comentado na seção 2.5.1.2, a análise de componentes principais (PCA) mostrou-se em um primeiro momento uma ferramenta com grande potencial para a análise e refinamento dos sinais, como uma etapa de pré-processamento. Porém, o algoritmo, como apresentado, apresenta algumas limitações à aplicação em um sistema ICC. Entre estas limitações está a necessidade de se conhecer *a priori* os dados para gerar a matriz de projeção para o espaço de componentes principais, ou a variação que pode

ocorrer nos sinais entre o momento de geração da matriz de projeção e o momento da sua utilização para processamento, devido à plasticidade cerebral. Isto ocorre porque como o algoritmo está baseado na utilização de um conjunto de autovetores que são calculados a partir de dados previamente adquiridos, se as condições do sujeito mudam, como as mudanças geradas pela aprendizagem, as componentes sobre as quais se projetam os dados já não correspondem às componentes ideais selecionadas previamente para a aplicação.

O mesmo ocorre quando se pretende utilizar a matriz de projeção para a eliminação de ruído, pois se ocorrer alguma mudança nas características do ruído entre o treinamento e a utilização final, a matriz pode eliminar alguma componente de interesse para a aplicação, se esta matriz for estática.

Por estes motivos o algoritmo PCA, como descrito neste documento, foi descartado da aplicação final.

A análise com componentes independentes (ICA) foi utilizada inicialmente neste trabalho em alguns experimentos para a eliminação de ruído, mas devido à característica de que todas as componentes geradas pelo algoritmo possuem a mesma variância, e a que a ordem com a qual as componentes são geradas também é indeterminada, conforme discutido na seção 2.5.1.3, não é possível identificar, *a priori*, a importância de cada uma das componentes para a aplicação.

Alguns artigos da bibliografia (LOTTE et al., 2007; NICOLAS-ALONSO; GOMEZ-GIL, 2012; CHIAPPA; BARBER, 2005; KIM et al., 2017) utilizam as componentes independentes como algoritmo de pré-processamento para a geração de características e eliminação de artefatos, as quais foram testadas no laboratório, mas foram descartadas do sistema final, sendo que a decisão de não utilizar o método deve-se ao elevado custo computacional para a geração da matriz de projeção. A proposta deste método de eliminar ruído consiste em eliminar as componentes que podem concentrar o ruído e então reconstruir o sinal sem estas componentes, entretanto, observou-se que, operando desta forma, componentes de interesse são eliminadas conjuntamente com os sinais de ruído, pois estes se diluem em todas as componentes e não se concentram, como no processamento utilizando PCA.

4.2 Algoritmos de extração de características

Os algoritmos de extração de características estudados foram apresentados na seção 2.5.2. Nesta seção são analisados os algoritmos utilizados na implementação do sistema.

4.2.1 Análise de componentes de frequência

As componentes de frequência foram utilizadas como características neste trabalho. Estas componentes foram utilizadas para que o conhecimento *a priori* das características de ativações das regiões do cérebro onde se localizam os eletrodos possam ser utilizadas para a classificação.

As características de frequência utilizadas se baseiam no fato de que a inatividade em uma determinada região do cérebro é caracterizada pela presença da banda *alfa*, também chamada de sincronização relacionada a eventos, sendo que a execução de uma tarefa provoca uma desincronização (MÜLLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999). A atividade coordenada de uma região do cérebro está caracterizada pela atenuação desta banda de frequência, sendo que na região motora, como a que se utiliza neste trabalho, ocorre um aumento na energia da banda *beta*, ao redor da frequência característica da banda μ (MÜLLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Entre os algoritmos utilizados para a extração das características estão a transformada de Fourier e a energia dos sinais filtrados por bancos de filtros passa-banda (NICOLAS-ALONSO; GOMEZ-GIL, 2012; WARD, 2003; BAIG et al., 2014).

Na implementação do sistema proposto, procurou-se agrupar componentes de frequência que caracterizam as intenções do sujeito. Se os filtros passa-banda são utilizados, é necessário que estes possuam uma ordem alta para que as suas saídas possam ser seletivas com relação às frequências desejadas. Entretanto, esta implementação gera atrasos devido à ordem dos filtros, o que acarreta um atraso entre a intenção do sujeito e a geração das características (WANG; DENG; HE, 2004).

A transformada de Fourier, por outro lado, proporciona uma imagem das características de frequência do sinal na janela de tempo considerada para a análise. Neste caso, foi utilizada uma janela móvel de 1 s, gerando as componentes de frequência que serão utilizadas como características para o classificador. A janela de 1 s com sobreposição variável de 0,7 a 0,9 s, dependendo do usuário, foi escolhida devido a que o instante da execução da tarefa não é conhecido, então um monitoramento constante é necessário (ALONSO; VELLASCO, 2016; NICOLAS-ALONSO; GOMEZ-GIL, 2012). A cada janela amostrada, são calculados os coeficientes da FFT e, destes coeficientes, são retiradas as características que serão utilizadas no classificador.

Como a frequência de amostragem utilizada na captura de sinais pelo BrainNet foi de 200 Hz e a transformada é calculada sobre uma janela de 200 amostras, os coeficientes de frequência correspondem ao último segundo de atividade mental do indivíduo. Como o número de amostras é igual à frequência de amostragem, a resolução das componentes é de 1 Hz para cada amostra.

Com o intuito de reduzir o número de características utilizada no classificador, um algoritmo de seleção de características foi utilizado para reduzir este número de forma a otimizar a execução do classificador. Este algoritmo de seleção está baseado no ranqueamento das características utilizando o algoritmo de entropia relativa para cada uma das classes, como já citado na seção 2.5.2. A seleção das características é feita considerando as frequências das características mais importantes das três classes. Desta forma, cada sujeito possui um conjunto de características particular.

4.3 A rede neural SOM como classificador

A rede neural SOM foi selecionada nesta Tese de Doutorado como classificador para a geração de saídas para a Interface Cérebro–Computador implementada. A escolha desta arquitetura se deve à característica da rede SOM de organizar-se de acordo com as características apresentadas em sua entrada durante o treinamento, formando grupos nas saídas que podem ser associados a classes (KOHONEN, 2001; VESANTO; ALHONIEMI, 2000). Estes grupos possuem uma dependência dos valores de inicialização da rede no momento de sua criação, antes do início do treinamento da rede. Assim como forma de reduzir a dependência dos valores iniciais, as redes foram criadas utilizando os mesmos valores para diferentes sujeitos.

Pode-se atualizar a rede SOM de tempos em tempos para que a mesma atualize-se aos padrões gerados pelo sujeito. Sabe-se que os padrões de ativação do córtex cerebral se alteram constantemente, sendo que as ICCs devem se adaptar de forma muito similar à adaptação sensorial que ocorre quando os impulsos nervosos seguem os caminhos naturais de retroalimentação sensorial (WOLPAW et al., 2000; LEBEDEV; NICOLELIS, 2006; GANGULY; CARMENA, 2009; ALONSO; VELLASCO, 2016). Esta característica pode ser utilizada conjuntamente com a rede SOM para gerar novas saídas e ampliar as funções do sistema, ou melhorar as funções predefinidas através do remapeamento das saídas do sistema a essas novas funções utilizando algum tipo de realimentação.

A saída da rede SOM representa a saída de todos os neurônios, podendo-se etiquetar os neurônios com a probabilidade de pertencer a uma ou outra classe do grupo de dados de treinamento e, desta forma, avaliar se a ativação do neurônio caracteriza a ativação de uma determinada classe ou outra, visto que um mesmo neurônio pode ser ativado em mais de uma classe. A identificação das classes é feita através do uso de um conjunto de máscaras de classificação geradas durante a etapa de treinamento, com base nas tarefas propostas. O método usado para a criação das máscaras é apresentado na seção 4.3.1.

4.3.1 Criação e interpretação das máscaras de classificação das saídas da rede SOM

A rede SOM possui uma arquitetura similar à estrutura do córtex cerebral (KOHO-NEN, 2001; HAGAN et al., 2014). Desta forma, não possui uma saída única para cada classe como as redes MLP ou LVQ. Entretanto, a saída da rede precisa ser interpretada de alguma forma para gerar as saídas classificadas com base na capacidade de generalização da rede. Uma das formas de classificação da informação gerada pela rede SOM é a implementação de uma rede similar à LVQ, ou seja, uma rede neural MLP classificando a saída da rede SOM. Foram feitos alguns testes com a rede LVQ e esta apresentou resultados similares ao resultado do algoritmo desenvolvido com o uso de redes SOM e máscaras de classificação, porém, com um custo computacional maior, principalmente na etapa de treinamento. Por este motivo não foram adicionados aqui.

A geração das máscaras de classificação é realizada em conjunto com o treinamento da rede e utilizando os dados do conjunto de treinamento. Durante o treinamento da rede, os dados são apresentados a esta por um número de trechos (épocas ou *epochs*) suficientes para que a rede forme os grupos nas saídas a partir das informações dos dados. Este treinamento é realizado de forma não supervisionada, e o número de épocas é definido a partir de testes empíricos realizados com as redes. Nestes testes, que sempre utilizavam a mesma rede como ponto de partida para minimizar os efeitos da inicialização, observou-se que a partir de 100 repetições ou épocas, as disposições dos valores de saída não se alteravam, então utilizou-se este número como valor padrão para o treinamento das redes.

Após o treinamento da rede, os mesmos dados utilizados no treinamento foram apresentados a esta e as saídas foram observadas. Como os dados de treinamento foram rotulados durante a captura destes de acordo com a tarefa mental a ser realizada, associou-se cada neurônio a uma classe, para uma amostra. Repetindo-se este processo para todas as amostras e somando a quantidade de vezes que cada saída da rede foi ativada para cada classe, é possível formar um mapa de ativações que dá também a informação de qual saída foi mais ativa para uma determinada classe. Repetindo-se este processo para cada uma das três classes obtêm-se três máscaras que representam a quantidade de vezes que cada neurônio foi ativado para cada uma das máscaras. Dividindo-se as máscaras assim geradas pelo número de ativações de cada máscara, obtêm-se a máscara de probabilidade de ativação para cada neurônio. Como existe a possibilidade de que um neurônio esteja ativo em mais de uma tarefa mental, este paradigma de máscaras de probabilidade representa uma melhoria em relação ao uso de máscaras fixas, onde cada neurônio representa uma única classe.

Para o sistema implementado, com três classes diferentes, o conjunto de máscaras é formado por três conjuntos de valores que representam a probabilidade de que cada neurônio pertença a uma classe. A geração da saída ocorre da análise das probabilidades

representadas nas máscaras, de forma que a cada saída da rede os valores das probabilidades associadas ao neurônio ativo da rede naquele momento são verificadas. A máscara que possuir a maior probabilidade será a máscara vencedora, caracterizando a classe à qual pertence a entrada naquele instante.

Para reduzir a variabilidade na classificação, foi implementada uma técnica de reclassificação utilizando-se as saídas da rede nas últimas 4 a 6 classificações anteriores, dependendo do usuário e, assumindo-se que as classificações da rede são eventos independentes, a saída será a que apresentar maior probabilidade conjunta dada pelo produto das probabilidades observadas nos eventos de classificação anteriores.

4.4 Validação dos dados experimentais *on-line* utilizando as características de frequência dos sinais adquiridos

Observou-se nas características de frequência que as mesmas permanecem com pequenas alterações durante a execução de uma tarefa mental. Baseando-se nos resultados obtidos neste estudo da variabilidade das características de frequência dos dados experimentais, desenvolveu-se um método de validação dos dados para execução *on-line*, o qual está baseado na medição da variabilidade das características extraídas dos sinais.

O método, apresentado em (BUENO; PONS, 2006), está baseado em utilizar as características de frequência do sinal para determinar um índice que avalie a qualidade do mesmo, de forma *on-line*. As características de frequência dos sinais EEG possuem uma certa correlação entre seus valores ao longo do tempo em uma mesma tarefa mental. O ruído, por outro lado, pode ser gerado por fontes externas, e apresenta características de frequência desconhecidas. Um sinal EEG com elevados níveis de ruído apresenta, portanto, componentes de frequência que mudam com uma dinâmica muito diferente da dinâmica dos sinais EEG, os quais, durante uma tarefa, apresentam variações lentas nos coeficientes de frequência, quando comparados a sinais contaminados com níveis não aceitáveis de ruído. Utilizando esta premissa e observando os dados capturados nos experimentos realizados, criou-se um algoritmo capaz de estimar a qualidade dos sinais através do cálculo da correlação entre amostras características em instantes de tempo próximos. A Figura 25 representa o diagrama de blocos do algoritmo de validação implementado.

Na Figura 25 pode-se observar um diagrama de blocos representativo do algoritmo para a determinação do índice utilizado para avaliar a qualidade do sinal durante a aquisição. Nesta figura estão representados o cálculo das componentes de frequência utilizando a FFT de cada um dos canais adquiridos, a separação das características utilizadas para a análise que cobrem as bandas α e β do espectro do sinal EEG. Após a seleção das características, estas são concatenadas formando um vetor. A partir deste vetor, é calculada a correlação entre o valor atual e um valor passado. A diferença entre os instantes de tempo

é representada pelo bloco de atraso no diagrama da Figura 25.

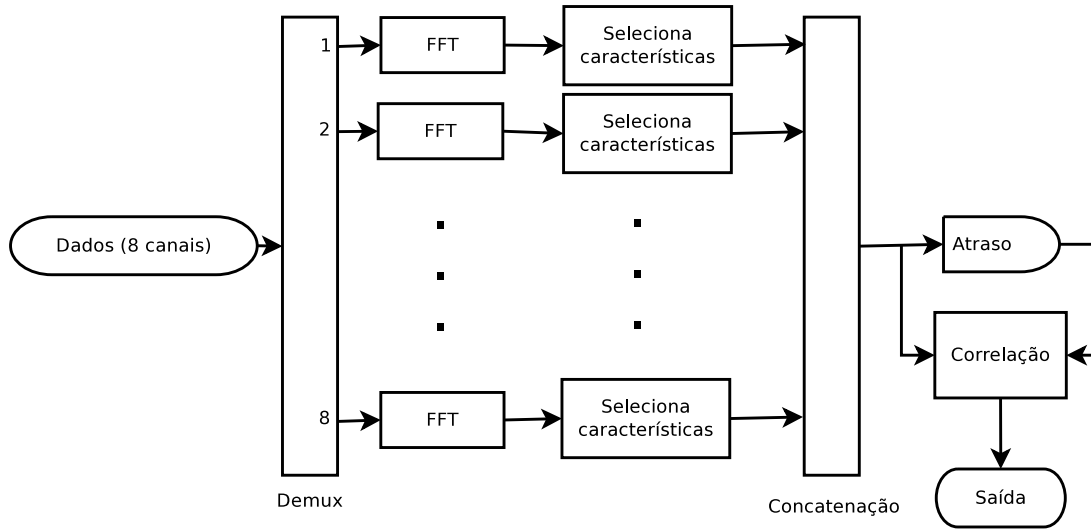


Figura 25 – Diagrama de blocos do algoritmo de validação de dados utilizando as componentes de frequência. Figura do autor.

O algoritmo consiste em avaliar a correlação entre as características selecionadas do sinal em instantes de tempo diferentes. De acordo com (HUIGEN; PEPER; GRIMBERGEN, 2002), o ruído devido ao contato entre o eletrodo e o eletrólito utilizado para a captura de sinais bioelétricos, e também entre o eletrólito e a pele para a faixa de frequência de até 30 Hz, são caracterizados por possuírem uma distribuição de espectro segundo a fórmula $S(f) = k/f^\alpha$ com $1,5 < \alpha < 2$ e k sendo uma constante. Segundo (KESHER, 1982), os processos aleatórios com distribuição de frequências segundo a fórmula $S(f) = k/f^\alpha$, com α próximo de 2, possuem uma função de autocorrelação que varia com o tempo de atraso considerado na análise de autocorrelação. Como o tempo de atraso no cálculo da correlação é constante, a correlação do ruído pode ser considerada constante para este tipo de ruído, diminuindo à medida que o tempo considerado aumenta.

Ainda segundo (HUIGEN; PEPER; GRIMBERGEN, 2002), a impedância de contato entre o eletrodo e a pele influencia a qualidade do sinal, sendo que para grandes impedâncias, o ruído de contato pode chegar à faixa dos mV , superando a faixa dinâmica do sinal EEG que está na faixa dos μV .

Utilizando este algoritmo, também é possível observar, de maneira geral, as mudanças nas características que ocorrem durante a execução das tarefas mentais. Quando o sujeito passa de uma tarefa para outra, passando pela apresentação do estímulo, são observadas mudanças na saída do algoritmo. Esta variação pode ser interpretada como mudanças nas características no próprio sinal EEG. Na Figura 26, podem-se observar os resultados do algoritmo de validação de dois experimentos. Como já citado anteriormente, uma vez que o tempo entre os instantes para o cálculo da correlação é constante, a correlação do ruído de contato será constante, sempre que a impedância do contato per-

manecer constante. Desta forma, se considerarmos que as condições do experimento são constantes, as variações na saída do algoritmo serão dependentes apenas das variações no sinal devido às características de interesse, variações provocadas por ruído provenientes de outras fontes, como EMG ou EOG, ou ainda devido a ativações de áreas próximas dos eletrodos, porém não relacionadas à tarefa de interesse.

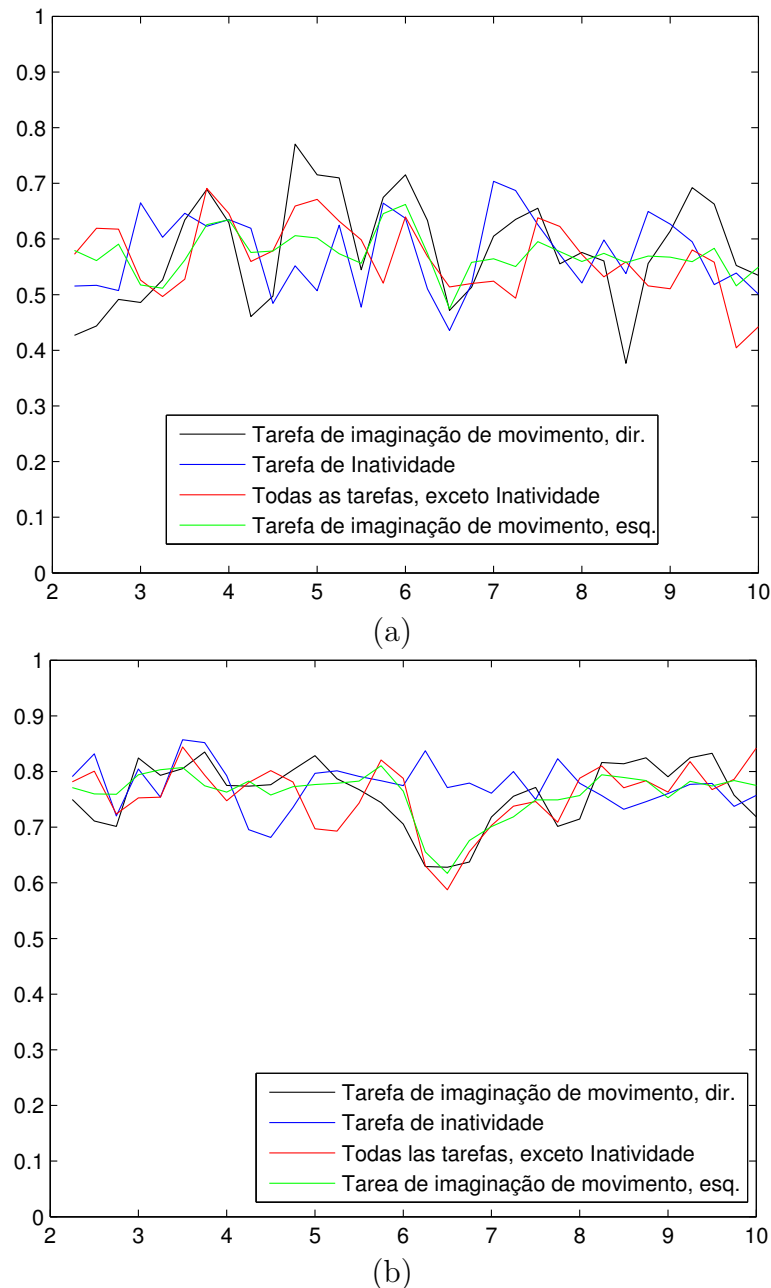


Figura 26 – Representação dos dados de correlação resultantes da validação dos dados experimentais. (a) Dados inaceitáveis: observa-se uma correlação baixa (ao redor de 0,5) e não se observam mudanças durante a execução da tarefa. (b) Dados aceitáveis: observa-se uma correlação alta (ao redor de 0,75) nas tarefas inicial e de imaginação de movimento; a apresentação e retirada do estímulo geram grandes mudanças nas características, resultando em uma baixa correlação. Figura do autor.

O algoritmo desenvolvido utiliza um conjunto de componentes de frequência que

cobre as bandas alfa e beta do sinal EEG de todos os canais disponíveis, evidenciando mudanças em quaisquer componentes de quaisquer eletrodos aplicados no couro cabeludo do usuário. Como o algoritmo proporciona informação a respeito da variabilidade das componentes de frequência, pode-se utilizá-lo para identificar a qualidade do sinal. Para isto, o sujeito deve concentrar-se em uma tarefa por alguns instantes. Se a saída do algoritmo apresenta valores muito baixos e com muita variação em seu valor, pode-se assumir que algum eletrodo está com um nível de ruído muito elevado. Exemplos de dados de saída do algoritmo podem ser vistos na Figura 26.

4.5 O sistema implementado

Nesta seção se descreve o sistema implementado, no qual é necessária uma etapa inicial de experimentos *off-line* para o treinamento dos classificadores, para depois iniciarem-se os experimentos *on-line*.

4.5.1 A implementação final

A implementação final do sistema está baseada em um PC e utiliza o BraiNet - BNT36 como equipamento de aquisição de sinais EEG e um programa desenvolvido no ambiente Matlab para controlar o dispositivo de captura de dados. A este computador está também conectado um segundo monitor, o qual é utilizado tanto para apresentação dos estímulos ao sujeito durante a etapa de treinamento quanto como forma de realimentação da saída do algoritmo de classificação. Para o caso da utilização do sistema para o controle de dispositivos como uma cadeira de rodas ou um ambiente inteligente, as saídas classificadas do sistema podem ser enviadas ao dispositivo final utilizando uma placa microcontrolada com saídas comandadas pelo algoritmo para controlar estes dispositivos externos. O sistema implementado está pronto para esta implementação, embora não tenha sido realizado o controle dos dispositivos finais, mas apenas os testes de comunicação do Matlab com a placa microcontrolada.

O sistema final utiliza como classificador a rede auto organizada (SOM) associado às máscaras de classificação criadas, conforme apresentado na seção 4.3.1.

Os resultados finais de classificação estão apresentados no Capítulo 6

4.6 Discussão do capítulo

Neste capítulo foram apresentados os algoritmos utilizados na implementação dos programas para o sistema de análise de sinais EEG da ICC descrita nesta Tese de Doutorado.

Cada um dos algoritmos utilizados no trabalho foi discutido nesta Tese de Doutorado para justificar sua utilização. Para a classificação foi utilizado o algoritmo SOM, o qual utiliza a energia das componentes de frequência obtidas pela transformada de Fourier como características. As características foram selecionadas utilizando inicialmente o conhecimento a priori das funções cerebrais e também um algoritmo automático baseado na entropia relativa das características para as tarefas estudadas.

Também se apresentou neste capítulo o algoritmo de validação de dados baseado na análise das características de frequência dos sinais ao longo do tempo, desenvolvido ao longo do trabalho, e a estrutura de máscaras para interpretar as saídas da rede SOM.

5 Resultados

Neste capítulo, apresentam-se os resultados obtidos com o uso do algoritmo aplicado a sinais de uma base de dados disponível na internet, na etapa de desenvolvimento inicial, para então passar à etapa de testes com voluntários do laboratório.

Além destes resultados dos testes com base de dados e com os voluntários do laboratório, são apresentados dados relacionados à escolha dos voluntários, além da forma como são escolhidos os parâmetros do classificador.

Todos os experimentos realizados foram conduzidos seguindo normas de segurança elétrica, utilizando aparelhos certificados pela ANVISA, de acordo com autorização do comitê de ética em pesquisa registrado na Plataforma Brasil – CAAE: 64797816.7.0000.5542.

5.1 Escolha dos voluntários para participação os experimentos

Para participação nos experimentos foram escolhidos voluntários entre os alunos do NTA/UFES. Três alunos participaram dos experimentos de coleta de sinais EEG, sendo que os dados de um deles não foi possível de ser utilizado devido à baixa qualidade, fruto de excesso de contaminação por EMG devido à movimentação excessiva desse voluntário durante a execução do experimento.

A faixa etária dos participantes nos experimentos variou dos 23 até os 35 anos, todos homens, e nenhum dos participantes possui limitação motora ou cognitiva.

5.2 Escolha de parâmetros do classificador

Em princípio, o algoritmo permite que se personalize o classificador para cada um dos usuários, desde o número de características até o número de neurônios no classificador. Esta última escolha não foi automatizada, devendo ser realizada manualmente através de simulações nos conjuntos de dados utilizados no experimento, ou fixada ao início do mesmo para todos os usuários.

Devido a esta liberdade de escolha de parâmetros para personalizar o sistema ao sujeito, foram testadas algumas arquiteturas diferentes antes de chegar-se a uma estrutura personalizada para cada um dos sujeitos participantes dos testes. Buscou-se, então, um equilíbrio entre a dimensão da rede e a acurácia desejada na classificação.

Os resultados são apresentados a seguir em conjunto com as características de cada uma das redes utilizadas com os dados de cada sujeito.

Como parâmetro de comparação de desempenho utilizou-se a mesma estrutura de classificador (SOM + máscaras de probabilidade) com diferentes conjuntos de características, sendo elas: conjunto completo de componentes de frequência abrangendo as bandas alfa e beta do espectro de EEG (8 a 30 Hz); somente a faixa de frequências que compreende a banda alfa e a banda mu (8 a 13Hz); e as componentes calculadas pelo algoritmo de seleção de características nos 8 canais de EEG que são capturados pelo sistema.

As características utilizadas para a classificação foram selecionadas utilizando-se como base a divergência de Kullback–Leibler gerando conjuntos de características individualizados para cada um dos sujeitos que participaram da análise.

São apresentados os resultados médios para os sujeitos avaliados e as situações limites: melhor e pior caso de classificação. Os dados são apresentados na forma de matriz de confusão e acurácia na classificação total.

A matriz de confusão condensa a informação de classificações da saída do classificador com relação à classe pretendida e o valor de acurácia representa uma taxa de acerto geral, independente da classe a que se refere a saída.

5.3 Comparação dos resultados de classificação

Nesta seção são apresentados os resultados obtidos com os dados de banco de dados e com os dados de voluntários do laboratório. Vale ressaltar que, segundo (KÜBLER et al., 2001), baseado em vários anos de estudos com ICCs para comunicação, uma acurácia em torno de 70% é considerada útil como interface de comunicação, ainda que com uma velocidade mais baixa. Valores muito inferiores comprometem a utilização da interface.

Por outro lado, o sistema, como implementado possui três classes, seu valor aleatório teórico é de 33,3% de acurácia, mas, de acordo com (MÜLLER-PUTZ et al., 2008), e considerando um nível de confiança de 5%, o valor correspondente ao aleatório, considerando o número de repetições por tarefa utilizado nos experimentos, nos dá um valor mínimo de acurácia de 37,7%. Abaixo deste valor, o classificador não oferece nenhuma vantagem sobre uma escolha aleatória.

5.3.1 Resultados utilizando bancos de dados

Os resultados utilizando sinais EEG do bancos de dados do BCI Competition III (BLANKERTZ, 2005) para tarefas mentais utilizadas neste trabalho estão representadas nas figuras e tabelas a seguir para cada um dos usuários do banco de dados. Este banco de dados possui sinais EEG de três voluntários executando as mesmas tarefas mentais utilizadas nesta pesquisa de Doutorado.

O conjunto de tarefas utilizadas neste trabalho é composto por duas tarefas de

imaginação motora e uma cognitiva. Estas tarefas são a imaginação de movimento da mão direita (IMD), imaginação de movimento da mão esquerda (IME), e a tarefa cognitiva é recordar palavras que se iniciam com uma mesma letra, a ser escolhida pelo sujeito. Vale ressaltar que estas tarefas continuam sendo utilizadas por vários grupos de pesquisa do mundo em projetos envolvendo o desenvolvimento de ICCs (KIM et al., 2017; ACQUALAGNA et al., 2016; PEI; ZHENG, 2008; BAIG et al., 2014).

Na Tabela 1 podem-se observar os resultados para os dados do BCI Competition, onde pode-se verificar que o primeiro voluntário supera o limite mínimo experimental de 70%, o que permitiria o uso desta ICC como equipamento de comunicação. Para o voluntário 2, a acurácia está acima do limite mínimo para ter um desempenho superior ao aleatório, considerando um nível de confiança de 95%, que é de 37,7%. Entendemos que o sistema realmente poderia ser utilizado, porém com grande penalização no seu desempenho. O terceiro usuário apresenta valores de classificação praticamente aleatórios, visto que o nível de acerto, para ser melhor que uma classificação aleatória, deveria ser de 37,7%.

Tabela 1 – Demonstrativo dos resultados dos testes realizados com dados do BCI Competition.

Voluntário	Tamanho da rede	Número de características	Acurácia
1	5×5	48	71,21 %
2	5×5	40	56,41 %
3	5×5	40	38,87 %

A seguir são apresentados os resultados individuais para cada um dos voluntários avaliados. A Figura 27 apresenta a saída para o voluntário 1, e sua matriz de confusão está mostrada na Tabela 2.

Tabela 2 – Matriz de confusão para o voluntário 1 utilizando a rede com 25 neurônios (matriz quadrada, 5×5) e 40 características, treinados com 100 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras.

	Classe real		
	Palavra	IME	IMD
Classificado			
Palavra	71,03%	4,08%	24,88%
IME	2,84%	72,90%	24,26%
IMD	18,17%	4,84%	76,99%

As máscaras utilizadas para a classificação do voluntário 1 estão mostradas na Figura 28.




Figura 27 – Saída do classificador para os dados de verificação do voluntário 1. Valor esperado no traço em (a), e saída do classificador marcada com ‘*’ em (b). Figura do autor.




Figura 28 – Máscaras relacionadas ao voluntário 1. Em *a* estão representadas as máscaras de classificação utilizadas, e em *b* uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.

De acordo com a Tabela 2, o primeiro voluntário apresentou resultados de classificação correta superiores a 70% em todas as tarefas executadas. Desta forma, pode-se

afirmar que ele poderia utilizar este sistema sem grandes dificuldades.

A Figura 29 apresenta a saída para o voluntário 2, e sua matriz de confusão é mostrada na Tabela 3.




Figura 29 – Saída do classificador para os dados de verificação do voluntário 2. Valor esperado no traço em (a), e saída do classificador marcada com “*” em (b). Figura do autor.

Tabela 3 – Matriz de confusão para o voluntário 2 utilizando a rede com 25 neurônios (matriz quadrada, 5×5) e 40 características, treinados com 100 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras.

	Classe real		
	Palavra	IME	IMD
Classificado			
Palavra	69,40%	7,06%	23,54%
IME	33,05%	36,09%	30,86%
IMD	26,64%	10,29%	63,07%

As máscaras utilizadas para a classificação do voluntário 2 estão mostradas na Figura 30.

De acordo com a Tabela 3 O segundo voluntário apresentou resultados de classificação correta próximos a 70% (69,4% e 63,07%) para duas das três tarefas, mas apresentou um resultado aleatório para a tarefa IME. Para este usuário a utilização do sistema seria restrito apenas às tarefas IMD e Palavra, reduzindo a utilidade da interface.




Figura 30 – Máscaras relacionadas ao voluntário 2. Em *a* estão representadas as máscaras de classificação utilizadas, e em *b* uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.

A Figura 31 apresenta a saída para o voluntário 3, e sua matriz de confusão é mostrada na Tabela 4.




Figura 31 – Saída do classificador para os dados de verificação do voluntário 3. Valor esperado no traço em (a), e saída do classificador marcada com ‘*’ em (b). Figuras do autor.

Tabela 4 – Matriz de confusão para o voluntário 3 utilizando a rede com 25 neurônios (matriz quadrada, 5×5) e 40 características, treinados com 100 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de movimento da Mão Direita – IMD, Imaginação de movimento da Mão Esquerda – IME, e recordar Palavras.

	Classe real		
	Palavra	IME	IMD
Classificado			
Palavra	37,82%	19,97%	42,21%
IME	13,31%	42,18%	44,51%
IMD	14,99%	42,87%	42,14%

As máscaras utilizadas para a classificação do voluntário 3 estão mostradas na Figura 32.




Figura 32 – Máscaras relacionadas ao voluntário 3. Em *a* estão representadas as máscaras de classificação utilizadas, e em *b* uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.

De acordo com a Tabela 4, o terceiro voluntário apresentou resultados de classificação correta muito próximos ao nível aleatório e, portanto, para este voluntário o sistema não pode ser utilizado. Vale ressaltar que algumas pessoas têm dificuldade em gerar os padrões de EEG de forma que possam ser identificados, e isto é bastante comum (ACQUALAGNA et al., 2016). Nestes casos, um treinamento do sujeito acompanhado de ajustes nos parâmetros do sistema ICC são necessários, de forma que o usuário passa a apresentar resultados satisfatórios.

5.3.2 Resultados com dados dos voluntários do laboratório

Também foram realizados experimentos com três voluntários do NTA, e os resultados são apresentados na Tabela 5.

A avaliação dos resultados segue o mesmo parâmetro apresentado no início da seção.

Tabela 5 – Demonstrativo dos resultados dos experimentos realizados no laboratório.

Voluntário	Tamanho da rede	Número de características	Acurácia
A	6×6	38	66,24 %
H	6×6	60	56,91 %
V	6×6	60	40,12 %

Observa-se que os dois primeiros voluntários apresentaram valores que podem ser considerados próximos ao mínimo de 70% para a utilização satisfatória de um sistema ICC, segundo (KÜBLER et al., 2001), entretanto, um usuário ficou próximo do nível aleatório para três classes (37,7%), segundo (MÜLLER-PUTZ et al., 2008).

Para cada um dos resultados listados na Tabela 5 se apresenta uma matriz de confusão e um gráfico que ilustram o comportamento da saída do classificador, para cada voluntário, além de uma figura que ilustra as máscaras que representam a probabilidade de cada neurônio de pertencer a uma determinada classe.

A Figura 33 apresenta a saída para o voluntário A, e sua matriz de confusão é mostrada na Tabela 6.




Figura 33 – Saída do classificador para os dados de verificação do voluntário A. Valor esperado no traço, e saída do classificador marcada com ‘*’. Figura do autor.

Tabela 6 – Matriz de confusão para o voluntário A utilizando a rede com 36 neurônios (matriz quadrada, 6×6) e 38 características, treinados com 500 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras. A segunda metade da tabela apresenta resultados após a reclassificação das saídas.

	Classe real		
	Palavra	IME	IMD
Classificado			
Palavra	65,63 %	20,62 %	13,75 %
IME	9,04 %	72,89 %	18,07 %
IMD	33,13%	25,77 %	41,10 %

As máscaras utilizadas para a classificação do voluntário A estão mostradas na Figura 34.




Figura 34 – Máscaras relacionadas ao voluntário A. Em *a* estão representadas as máscaras de classificação utilizadas, e em *b* uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.

De acordo com a Tabela 6, o primeiro voluntário apresentou resultados de classificação correta próximos a 70% em duas das tarefas mentais (65,63% e 72,89%), e resultados próximos do aleatório de 37,7% em uma tarefa (41,1%). Para este usuário, a utilização do sistema seria restrita apenas às tarefas IME e Palavra, reduzindo a utilidade da interface.

A Figura 35 apresenta a saída para o voluntário H, e sua matriz de confusão é mostrada na Tabela 7.




Figura 35 – Saída do classificador para os dados de verificação do voluntário H. Valor esperado no traço, e saída do classificador marcada com ‘*’. Figura do autor.

Tabela 7 – Matriz de confusão para o voluntário H utilizando a rede com 36 neurônios (matriz quadrada, 6×6) e 60 características, treinados com 200 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras. A segunda metade da tabela apresenta resultados após a reclassificação das saídas.

	Classe real		
	Palavra	IME	IMD
Classificado			
Palavra	53,94 %	29,09 %	16,97 %
IME	18,18 %	77,58 %	4,24 %
IMD	24,03 %	38,31 %	37,66 %

As máscaras utilizadas para a classificação do voluntário H estão mostradas na Figura 36.




Figura 36 – Máscaras relacionadas ao voluntário H. Em *a* estão representadas as máscaras de classificação utilizadas, e em *b* uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.

De acordo com a Tabela 7, o segundo voluntário apresentou resultados de classificação correta próximos a 70% em duas das tarefas mentais (53,94% e 77,58%), mas resultados próximos do aleatório de 37,7% em uma tarefa (37,66%). Para este usuário, a utilização do sistema seria restrita apenas às tarefas IME e Palavra, reduzindo a utilidade da interface.

A Figura 37 apresenta a saída para o voluntário V, e sua matriz de confusão é mostrada na Tabela 8.

Tabela 8 – Matriz de confusão para o voluntário V utilizando a rede com 36 neurônios (matriz quadrada, 6×6) e 60 características, treinados com 200 épocas e classificadores ajustados automaticamente. A classificação se dá entre as classes Imaginação de Movimento da Mão Direita – IMD, Imaginação de Movimento da Mão Esquerda – IME, e recordar Palavras. A segunda metade da tabela apresenta resultados após a reclassificação das saídas.

	Classe real		
	Palavra	IME	IMD
Classificado			
Palavra	80,84%	3,59%	14,97%
IME	79,50%	9,94%	10,56%
IMD	67,47%	4,22%	28,31%




Figura 37 – Saída do classificador para os dados de verificação do voluntário V. Valor esperado no traço, e saída do classificador marcada com '*'. Figura do autor.

As máscaras utilizadas para a classificação do voluntário V estão mostradas na Figura 38.




Figura 38 – Máscaras relacionadas ao voluntário V. Em *a* estão representadas as máscaras de classificação utilizadas, e em *b* uma máscara realizada com os dados de verificação, onde podem-se observar os pontos de ativação da rede para cada uma das classes. Figuras do autor.

O terceiro voluntário apresentou um resultado tendencioso a escolher apenas uma das classes (com 80,84% de taxa de acerto), independente da entrada utilizada. Este resultado não é válido, e este usuário não está apto inicialmente a utilizar a interface. Observou-se também, durante a execução da tarefa, que o usuário não seguiu o protocolo experimental totalmente, resultando em dados contaminados por diferentes tipos de artefatos.

5.4 Considerações sobre o resultados apresentados

Nos dados do BCI Competition a análise mostra que a acurácia total, apesar de comprometida pelos dados do voluntário 3, ainda se mostra compatível com outros trabalhos utilizando os mesmos dados, como foi analisado em (BUENO; BASTOS FILHO, 2015b).

Como se pode observar na Figura 34(a), as ativações dos neurônios durante a etapa de treinamento formam grupos de ativações, embora todos os neurônios possuam uma pequena probabilidade de serem ativados por uma ou outra classe. Na Figura 34(b) observa-se que nos dados de treinamento a distribuição foi ligeiramente diferente, o que justifica uma certa redução na taxa de acerto, devido à ativação de neurônios pertencentes à mesma classe.

Como se pode observar na Figura 36(a), as ativações dos neurônios durante a etapa de treinamento formam grupos de ativações que, para este voluntário, não são tão bem definidos com os do voluntário A, devido à maior presença de ruído. Neste caso, todos os neurônios possuem uma pequena probabilidade de serem ativados por uma ou outra classe. Na Figura 36(b) observa-se que nos dados de treinamento a distribuição foi diferente do mapa apresentado na Figura 36(a), o que justifica uma redução maior da taxa de acerto devido à ativação de neurônios pertencentes à mesma classe. Pode-se observar que alguns dos neurônios se ativaram fortemente em todas as classes, o que reduz consideravelmente a acurácia final do sistema.

Na Figura 38(a) podem-se observar as ativações dos neurônios que, durante a etapa de treinamento, não são muito bem definidos, devido ao ruído, porém, de forma diferente dos apresentados para o voluntário H. Neste caso, alguns neurônios apresentam uma forte ativação enquanto outros não apresentam nenhuma ativação, como pode ser observado. Na Figura 38(b) observa-se que nos dados de treinamento a distribuição foi diferente do mapa apresentado na Figura 38(a), concentrando-se em poucos neurônios, independente da classe da entrada. Este comportamento se deve a que a natureza do ruído deste experimento é diferente do ruído presente no experimento do voluntário H. No caso do voluntário V, este se movia muito durante a execução do experimento, e o ruído provocado pelos sinais EMG (artefato) possui características diferentes do ruído

presente nos sinais do outro voluntário.

Concluimos que, nos dados coletados com voluntários do laboratório, foi observado que, devido principalmente à presença de ruído excessivo ou artefatos durante a captura dos dados, o classificador não consegue associar corretamente as características às classes. Nestas situações, o classificador apresenta uma saída mais aleatória que a desejada, ou pode gerar uma saída tendenciosa, como pode-se observar nos dados do sujeito V, apresentados na Figura 37, os quais apresentaram um resultado de saída praticamente constante e com pouca correlação com as tarefas mentais executadas. Nestes dados, observou-se uma grande contaminação nos sinais EEG, resultando, por isso, em uma baixa acurácia total em torno do valor aleatório de 37,7 %.

Os resultados apresentados aqui não invalidam a estrutura composta por uma rede neural SOM e um conjunto de máscaras como classificador. Apesar dos resultados de acurácia média próximos do valor da aleatoriedade em alguns casos, vale lembrar que todos os dados foram utilizados, sem nenhuma eliminação de contaminação por artefatos de qualquer origem. Já no caso da análise dos sinais do banco de dados, os quais foram captados em um ambiente controlado, foi possível superar o limite de 70% para todas as tarefas de um usuário. Vale ressaltar que os sinais capturados no laboratório foram captados em um ambiente não controlado, com outros computadores nas proximidades do sistema, e com outras pessoas no mesmo ambiente, o que pode também gerar estímulos auditivos em regiões próximas às regiões monitoradas, gerando interferências nos sinais capturados. Ressalta-se também que o sistema ICC aqui proposto justifica seu uso em pessoas que não podem realizar movimentos (como pessoas com ELA ou LIS), não gerando assim artefatos de EMG.

6 Conclusões e trabalhos futuros

A interface cérebro-computador (ICC) desenvolvida nesta Tese de Doutorado foi testada e validada de forma *off-line*, com sinais de bancos de dados externos (de três voluntários) de EEG, e com três voluntários do NTA, apresentando resultados considerados satisfatórios em ambas as situações.

6.1 Contribuições

As contribuições deste trabalho estão divididas em dois campos:

- Processamento de sinais: no que se refere ao desenvolvimento e aplicação de novos algoritmos de processamento de sinais EEG, para validação dos mesmos e para extração de características para classificação; e o desenvolvimento de um classificador baseado em rede neural de mapas auto-organizados (SOM) associada a máscaras de probabilidade das classes;
- Tecnológico: no que se refere ao desenvolvimento do sistema embarcado para captura, processamento e classificação *on-line* de sinais EEG, para auxílio a pessoas com deficiência motora severa, como pessoas com ELA ou LIS.

Cada um destes tópicos está detalhado a seguir, e na seção 6.2 estão apresentadas as publicações resultantes desta pesquisa.

6.1.1 Processamento de sinais

As contribuições no que diz respeito ao processamento de sinais se concentram no uso de ferramentas para atingir o objetivo de implementar a ICC proposta. A proposta original do trabalho foi utilizar ferramentas consolidadas e que pudessem ser implementadas em sistemas de baixo poder computacional, assim, optou-se por utilizar o módulo das componentes da transformada de Fourier como característica para o classificador. Desta forma, esta implementação pode ser utilizada em diversas arquiteturas que podem realizar esta operação em tempo real. A quantidade de ruído e de informação redundante nas componentes de frequência dos sinais EEG é muito grande e, a partir daí, desenvolveu-se um algoritmo de validação para avaliar o nível de ruído no sinal EEG como forma de gerar uma medida da qualidade do sinal, no que diz respeito ao ruído. No que tange à redundância das características, foi utilizada uma classificação das características com base na entropia relativa das mesmas, associada a um conhecimento *a priori* para diminuir o número de características utilizadas.

6.1.1.1 Algoritmo de validação de sinais EEG

Uma das contribuições deste trabalho foi o desenvolvimento de um algoritmo de validação de sinais EEG baseado nas características de frequência dos sinais. Este algoritmo está descrito com mais detalhe na seção 4.4.

Este algoritmo é capaz de identificar sinais de boa qualidade através da correlação das componentes de frequência dos sinais capturados em diferentes instantes de tempo. A Figura 26, apresentada no Capítulo 4, mostra a evolução da correlação entre as componentes de frequência para dois conjuntos de dados. Nesta figura se pode observar o momento da execução da tarefa mental por parte do sujeito.

O algoritmo pode também evidenciar o instante da apresentação do estímulo, pois acarreta muitas mudanças na distribuição dos potenciais ao longo do couro cabeludo provocados pelo estímulo visual.

Na Figura 26 também se pode observar que a correlação na execução da tarefa apresenta oscilações de menor amplitude que as presentes na etapa inicial, onde o sujeito não está concentrado em uma tarefa motora.

6.1.1.2 Seleção de características para o classificador

Para diminuir as dimensões do conjunto de características, foi utilizado um algoritmo que ordena as componentes de frequência selecionadas *a priori*, conhecendo-se a natureza das tarefas, através da entropia relativa, ou divergência de Kullback–Leibler. Este algoritmo determina uma medida de diferença entre duas distribuições estatísticas, considerando que cada componente possui uma distribuição diferente, sendo possível medir a diferença entre as distribuições e selecionar as que possuem maior diferença entre uma tarefa e outra.

O algoritmo trabalha somente com duas distribuições, portanto, os dados de três tarefas foram separados em distribuições do tipo $p(x) = x \in \text{classe } 1$ e $q(x) = x \notin \text{classe } 1$. Desta forma, foi possível ordenar as características devido à sua distância à classe invertida.

Este algoritmo foi utilizado para selecionar as características para o classificador neural.

6.1.1.3 Desenvolvimento do classificador neural

O classificador neural proposto neste trabalho utiliza a arquitetura SOM associada a um conjunto de máscaras geradas a partir dos dados de treinamento.

A rede SOM, apresentada na seção 4.3, é uma rede auto-organizada que se adapta aos dados apresentados durante o treinamento, apresentando na sua saída apenas um

neurônio ativado, ou seja, uma saída com valor diferente de zero, com todos os demais apresentando saída zero. Este tipo de ferramenta é utilizado para a visualização da relação entre amostras de dados multidimensionais, pois mesmo reduzindo a duas ou três dimensões para visualização da rede, as relações entre as amostras no espaço original não são alteradas.

A utilização da rede SOM como classificador apresenta alguns problemas, pois como uma rede com $n \times m$ neurônios possui $n \cdot m$ saídas, é preciso que estas saídas sejam associadas de alguma forma para que as classes sejam identificadas. Uma forma muito simples e utilizada inicialmente em (BUENO; PONS, 2007) é selecionar os neurônios que são ativados por uma classe e rotulá-los diretamente com a classe, entretanto, esta solução apresenta problemas quando um mesmo neurônio responde a mais de uma classe, como ocorre na prática. As classes, apesar de definidas no mapa, não possuem neurônios exclusivos, o que impossibilita este procedimento. Uma outra análise utiliza os dados de treinamento para gerar máscaras que representam a probabilidade de ativação de cada neurônio em cada classe. Desta forma, pode-se analisar, para cada saída, qual será a classe com maior probabilidade de representar o sinal de entrada, sendo que a classe com maior probabilidade será associada ao conjunto de características. Esta foi a técnica utilizada nesta Tese de Doutorado.

6.1.2 Desenvolvimento de um sistema embarcado de processamento *on-line*

O desenvolvimento de um sistema embarcado, utilizando um processador digital de sinais (DSP), para o processamento *on-line* foi outra das contribuições desta Tese de Doutorado (Apêndice A). Este desenvolvimento partiu das especificações mínimas de entradas e das especificações de processamento de dados necessários para a extração de características e classificação para a geração das saídas.

A proposta é que o sistema seja capaz de executar de forma *on-line* o algoritmo desenvolvido para o processamento dos sinais EEG utilizando as características de frequência do sinal, sendo que a estrutura do classificador é determinada através de uma análise prévia realizada por um algoritmo *off-line* executado no computador, sendo os coeficientes armazenados no sistema portátil.

O sistema foi idealizado para executar o mesmo classificador desenvolvido nesta Tese de Doutorado, baseado em uma rede SOM associada a matrizes de probabilidades. Este dispositivo ainda possui a capacidade de armazenar os dados capturados em um cartão de memória e de enviar as saídas classificadas através de uma conexão Bluetooth.

Com o desenvolvimento recente da eletrônica embarcada, no que tange ao poder de processamento em placas de desenvolvimento cada vez menores, e ao desenvolvimento de etapas analógicas específicas para a captura de sinais de EEG (Texas Instruments,

2017), o sistema desenvolvido tornou-se limitado frente às novas possibilidades existentes de implementação, e seu desenvolvimento foi abandonado, apesar de ter sido uma solução bastante avançada no momento de sua concepção.

Mais informações a respeito deste desenvolvimento estão no Apêndice A.

6.2 Publicações

As contribuições deste trabalho foram publicadas em diferentes artigos e capítulos de livros, listados a seguir:

Periódico

(BUENO; BASTOS FILHO, 2015a): Bueno, Leandro; Bastos Filho, Teodiano Freire. A self-organizing maps classifier structure for brain computer interfaces. *Research on Biomedical Engineering*. 2015, V. 31-3, p. 232-240.

Congressos

(BUENO; BASTOS FILHO, 2015b): Bueno, Leandro; Bastos-Filho, Teodiano Freire; Self-Organizing Maps as a Classifier for a Brain-Computer Interface System. *Proceedings of the 1st International Workshop on Assistive Technology*, 2015, p213-216

(BUENO; PONS; BASTOS FILHO, 2013): Bueno, Leandro; Pons, José Luis; Bastos-Filho, Teodiano Freire. An embedded system for an EEG based BCI,. *Proceedings of the 4th IEEE Biosignals and Biorobotics conference (ISSNIP)*, 2013.

(BUENO; BASTOS FILHO, 2012): Bueno, Leandro; Bastos-Filho, Teodiano Freire. Desarrollo de un sistema embebido para adquisición y análisis de señales de electroencefalografía (EEG). *Encuentros Iberoamericanos: Seminario CYTED de la Red Temática IBERADA - V Jornadas AITADIS de Tecnologías de Apoyo a la Discapacidad: Experiencias y Avances en Tecnologías de Accesibilidad para Personas con Discapacidad.*, 2012.

(BUENO et al., 2008a): Bueno, Leandro; Brunetti, Fernando; Frizera Neto, Anselmo; Pons, José Luis. Cognitive Human-Robot Interaction in Wearable Robots: Approaches and Algorithms. *Proceedings of the IEEE Conference on Robotics and Automation (ICRA-08)*. 2008.

(MORENO; BUENO; PONS, 2008a): Moreno, Juan Camilo; Bueno, Leandro; Pons, José Luis. Sensors, actuators and control in Wearable Robots. *Proceedings of the IEEE Conference on Robotics and Automation (ICRA-08)*. 2008

(OLAYA et al., 2008): Olaya, Andrés Felipe Ruiz; de Lima, Eduardo Rocon; Brunetti, Fernando J; Bueno, Leandro; Sastoque, Juan Camilo Moreno; Rovira, José Luis

Pons. NeuroLab: A multimodal networked exoskeleton for neuromotor and biomechanical research. *Proceedings of International Conference On Biomedical Electronics. - BIODEVICES 2008*. 2008. V. 2. p. 68-73.

(BUENO; PONS, 2007): Bueno, Leandro; Pons, José Luis. Un sistema de interfaz cerebro ordenador basado en redes neuronales auto-organizadas. *Actas de la XXVIII Jornadas de Automática*. 2007.

(BUENO; PONS, 2006): Bueno, Leandro; Pons, José Luis. Algoritmo de validación de datos de EEG basado en características de la FFT. *Actas de la XXVII Jornadas de Automática*. 2006. p. 1229-1234.

(BUENO et al., 2006): Bueno, Leandro; Pons, José Luis; Brunetti, Fernando; Barrientos, Antonio. Desarrollo de una herramienta de análisis múltiple de señales de electroencefalografía. Actas del IV Congreso Iberoamericano sobre tecnologías de apoyo a la discapacidad. 2006. V. II. P. CO145-CO148.

Capítulos de livros

(ARJUNAN et al., 2014): Arjunan, Sridhar; Kumar, Dinesh Kant; Bueno, Leandro; Mayor, John Jairo Villarejo. Upper Limb Prosthesis Devices. Em *Devices for Mobility and Manipulation for People with Reduced Abilities (Rehabilitation Science in Practice Series)*. 2014. pp. 179-196.

(BUENO et al., 2008b): Bueno, Leandro; Brunetti, Fernando; Frizera Neto, Anselmo; Pons, José Luis. Human-Robot Cognitive Interaction. Em *Wearable Robots: Biomechatronic Exoskeletons*. 2008. p. 87-126

(MORENO; BUENO; PONS, 2008b): Moreno, Juan Camilo; Bueno, Leandro; Pons, José Luis. Wearable Robot Technologies. Em *Wearable Robots: Biomechatronic Exoskeletons*. 2008. p. 165-200

6.3 Trabalhos futuros

Uma das propostas de trabalhos futuros é a de que se possa desenvolver uma ICC portátil capaz de auto treinar-se para eliminar a necessidade de longos experimentos *off-line* necessários para a determinação das componentes e dos coeficientes do classificador.

Para que este tipo de comportamento possa ser implementado, é necessário que o sistema seja capaz de identificar um estado mental realizado e verificar se o mesmo corresponde ao estado desejado. Uma forma de implementar isto seria identificar potenciais de erro através do processamento de sinais EEG do sujeito. Os potenciais de erro já são conhecidos e estão sendo estudados como uma maneira de identificar as decisões equivocadas tomadas pelo classificador e corrigi-las (FERREZ; MILLÁN, 2005; MIRANDA et

al., 2014). Esta possibilidade pode ser interessante do ponto de vista da atualização dos parâmetros do classificador, já que esta atualização poderia ser feita ao longo do uso da ICC, sem a necessidade de reconstrução de todo o classificador .

Uma ICC com estas características poderia ser utilizada em experimentos de longa duração, ou seja, estar em contato com o sujeito por um período de dias e não de minutos, como os implementados hoje em dia. Neste caso, seriam necessárias outras especificações de segurança elétrica para esta ICC, requerendo um reprojeto de algumas das etapas da mesma.

Referências

- ACQUALAGNA, L.; BOTREL, L.; VIDAURRE, C.; KÜBLER, A.; BLANKERTZ, B. Large-scale assessment of a fully automatic co-adaptive motor imagery-based brain computer interface. *PLoS ONE*, v. 11, n. 2, p. 1–19, 2016. ISSN 19326203. Citado 3 vezes nas páginas 64, 91 e 95.
- ALONSO, D. R.; VELLASCO, M. M. B. R. Spatial Filter comparison for a Brain Computer Interface. In: *2016 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*. IEEE, 2016. c, p. 1–6. ISBN 978-1-5090-5105-2. Disponível em: <<http://ieeexplore.ieee.org/document/7885718/>>. Citado 9 vezes nas páginas 43, 45, 48, 53, 62, 63, 79, 81 e 82.
- AMATO, F.; LÓPEZ, A.; PEÑA-MÉNDEZ, E. M.; VAÑHARA, P.; HAMPL, A.; HAVEL, J. Artificial neural networks in medical diagnosis. *Journal of Applied Biomedicine*, v. 11, n. 2, p. 47–58, 2013. ISSN 1214021X. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1214021X14600570>>. Citado na página 58.
- ARJUNAN, S.; KUMAR, D. K.; BUENO, L.; MAYOR, J. J. V. Upper Limb Prosthesis Devices. In: Bastos Filho, T. F.; KUMAR, D. K.; ARJUNAN, S. (Ed.). *Devices for Mobility and Manipulation for People with Reduced Abilities (Rehabilitation Science in Practice Series)*. 1. ed. [S.l.]: CRC Press, 2014. cap. Upper Limb, p. 179–196. Citado na página 107.
- ATENCIO, A. C. *A Novel Stimulation Paradigm for a Brain-Computer Interface Based on SSVEP*. 144 p. Tese (Doutorado) — Universidade Federal do Espírito Santo, 2015. Citado 3 vezes nas páginas 23, 36 e 68.
- BAEK, K.; DRAPER, B. A.; BEVERIDGE, J. R.; SHE, K. PCA vs ICA: A comparison on the FERET data set. In: *Proceedings of the 6th Joint Conference on Information Science (JCIS)*. [s.n.], 2002. p. 824–827. Disponível em: <citeseer.ist.psu.edu/baek02pca.html>. Citado na página 49.
- BAIG, M. Z.; JAVED, E.; AYAZ, Y.; AFZAL, W.; GILLANI, S. O.; NAVEED, M.; JAMIL, M. Classification of left/right hand movement from EEG signal by intelligent algorithms. In: *2014 IEEE Symposium on Computer Applications and Industrial Electronics (ISCAIE)*. IEEE, 2014. p. 163–168. ISBN 978-1-4799-4351-7. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7010230>> <http://ieeexplore.ieee.org/document/7010230/>>. Citado 2 vezes nas páginas 81 e 91.
- BASHASHATI, A.; FATOURECHI, M.; WARD, R. K. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Journal of Neural Engineering*, v. 4, p. R32—R57, 2007. Disponível em: <<http://stacks.iop.org/JNE/4/R32>>. Citado 3 vezes nas páginas 44, 56 e 57.
- BASHASHATI, A.; WARD, R. K.; BIRCH, G. E. A New Design of the Asynchronous Brain Computer Interface Using the Knowledge of the Path of Features. In: *Proceedings*

of the Second International IEEE EMBS Conference on Neural Engineering. [S.l.: s.n.], 2005. p. 101–104. ISBN 0-7803-8710-4. Citado na página 68.

BENEVIDES, A. B.; ATENCIO, A. C.; CASTILLO, J.; BASTOS FILHO, T. F. An Ethernet sniffer for On-line acquisition of EEG with the BrainNet36 ® device applied to a An Ethernet Sniffer for On-line Acquisition of EEG with the BrainNet36 R Device Applied to a BCI. In: *Biosignals and Biorobotics Conference (2014): Biosignals and Robotics for Better and Safer Living (BRC), 5th ISSNIP-IEEE*. [S.l.: s.n.], 2014. p. 1–6. Citado na página 76.

BENEVIDES, A. B.; BASTOS FILHO, T. F. Pseudo-Online Classification Mental Tasks Using Kullback-Leibler Symmetric Divergence. *Journal of Medical and Biological Engineering*, v. 32, n. 6, p. 411–416, 2012. Citado 2 vezes nas páginas 56 e 64.

BENEVIDES, A. B.; BASTOS FILHO, T. F.; SARCINELLI FILHO, M. Proposal of Brain-Computer Interface architecture to command a robotic wheelchair. In: *2011 IEEE International Symposium on Industrial Electronics*. IEEE, 2011. p. 2249–2254. ISBN 978-1-4244-9310-4. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper-.htm?arnumber=5984511>>. Citado na página 38.

BIAGETTI, G.; CRIPPA, P.; FALASCHETTI, L.; ORCIONI, S. Learning HMM state sequences from phonemes for speech synthesis. *Procedia - Procedia Computer Science*, The Author(s), v. 96, n. September, p. 1589–1596, 2016. ISSN 1877-0509. Disponível em: <<http://dx.doi.org/10.1016/j.procs.2016.08.206>>. Citado na página 57.

BILMES, J. *What HMMs Can Do*. Department of Electrical Engineering University of Washington Box 352500 Seattle, Washington 98195-2500, 2002. Citado na página 57.

BioSemi Instrumentation. *ActiveTwo: 280-channel, DC amplifier, 24-bit resolution, biopotential measurement system with Active Electrodes*. 2003. Disponível em: <<http://www.biosemi.com/products.htm>>. Citado na página 43.

BIRBAUMER, N.; Ramos Murguialday, A.; WEBER, C.; MONTROYA, P. Neurofeedback and brain-computer interface clinical applications. *International review of neurobiology*, Elsevier Inc., v. 86, n. 09, p. 107–17, jan 2009. ISSN 0074-7742. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/19607994>>. Citado na página 71.

BLANKERTZ, B. *BCI Competition III - Final Results*. 2005. 20 p. Disponível em: <<http://www.bbci.de/competition/iii/results/index.html>>. Citado na página 90.

BLANKERTZ, B.; ACQUALAGNA, L.; DÄHNE, S.; HAUF, S.; SCHULTZE-KRAFT, M.; STURM, I.; UŠĆUMLIĆ, M.; WENZEL, M. A.; CURIO, G.; MÜLLER, K.-R. The Berlin Brain-Computer Interface: Progress Beyond Communication and Control. *Frontiers in Neuroscience*, v. 10, n. NOV, nov 2016. ISSN 1662-453X. Disponível em: <<http://journal.frontiersin.org/article/10.3389/fnins.2016.00530/full>>. Citado 2 vezes nas páginas 64 e 67.

BLANKERTZ, B.; DORNHEGE, G.; SCHÄFER, C.; KREPI, R.; KOHLMORGEN, J.; MÜLLER, K.-R.; LOSCH, V. K. F.; CURIO, G. Boosting bit rates and error detection for the classification of fast-paced motor commands based on single-trial EEG analysis. 2003. 100–104 p. Disponível em: <http://www.first.fraunhofer.de/owx/_medien/pdf/559/_BlaDorSchKreKohMueKunLosCur>. Citado na página 67.

- BUENO, L.; BASTOS FILHO, T. F. Desarrollo de un sistema embebido para adquisición y análisis de señales de electroencefalografía (EEG). In: *Encuentros Iberoamericanos: Seminario CYTED de la Red Temática IBERADA - V Jornadas AITADIS de Tecnologías de Apoyo a la Discapacidad: Experiencias y Avances en Tecnologías de Accesibilidad para Personas con Discapacidad*. Vitória: [s.n.], 2012. Citado na página 106.
- BUENO, L.; BASTOS FILHO, T. F. A self-organizing maps classifier structure for brain computer interfaces. *Research on Biomedical Engineering*, v. 31, n. 3, p. 232–240, sep 2015. ISSN 2446-4740. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S2446-47402015000300232&lng=en&nrm>. Citado na página 106.
- BUENO, L.; BASTOS FILHO, T. F. Self-Organizing Maps as a Classifier for a Brain-Computer Interface System. In: *Proceedings of the 1st International Workshop on Assistive Technology*. Vitória: [s.n.], 2015. p. 213–216. Citado 3 vezes nas páginas 56, 101 e 106.
- BUENO, L.; BRUNETTI, F.; FRIZERA NETO, A.; PONS, J. L. Cognitive Human-Robot Interaction in Wearable Robots: Approaches and Algorithms. In: *Proceedings of the IEEE Conference on Robotics and Automation (ICRA-08)*. Pasadena: [s.n.], 2008. Citado na página 106.
- BUENO, L.; BRUNETTI, F.; FRIZERA NETO, A.; PONS, J. L. Human-Robot Cognitive Interaction. In: _____. *Wearable Robots: Biomechatronic Exoskeletons*. [S.l.]: John Wiley and Sons, Inc., 2008. cap. 4, p. 87–126. Citado na página 107.
- BUENO, L.; PONS, J. L. Algoritmo de validación de datos de EEG basado en características de la FFT. In: *Actas de la XXVII Jornadas de Automática*. Almeria, Spain: Comité Español de Automática, 2006. p. 1229–1234. Citado 3 vezes nas páginas 53, 84 e 107.
- BUENO, L.; PONS, J. L. Un sistema de interfaz cerebro ordenador basado en redes neuronales auto-organizadas. In: *Actas de la XXVIII Jornadas de Automática*. Huelva, Spain: Comité Español de Automática, 2007. Citado 2 vezes nas páginas 105 e 107.
- BUENO, L.; PONS, J. L.; BASTOS FILHO, T. F. An embedded system for an EEG based BCI. In: *Proceedings of the 4th IEEE Biosignals and Biorobotics conference (ISSNIP)*. Rio de Janeiro: [s.n.], 2013. Disponível em: <http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6487>. Citado na página 106.
- BUENO, L.; PONS, J. L.; BRUNETTI, F.; BARRIENTOS, A. Desarrollo de una herramienta de análisis multiple de señales de electroencefalografía. In: FERREIRA, A.; FRIZERA NETO, A.; BASTOS FILHO, T. F. (Ed.). *Actas del IV Congreso Iberoamericano sobre tecnologías de apoyo a la discapacidad*. [S.l.: s.n.], 2006. II, p. CO145–CO148. Citado 3 vezes nas páginas 51, 52 e 107.
- BUNDY, D. T.; SOUDERS, L.; BARANYAI, K.; LEONARD, L.; SCHALK, G.; COKER, R.; MORAN, D. W.; HUSKEY, T.; LEUTHARDT, E. C. Contralesional Brain-Computer Interface Control of a Powered Exoskeleton for Motor Recovery in Chronic Stroke Survivors. *Stroke*, v. 48, n. 7, p. 1908–1915, 2017. ISSN 15244628. Citado na página 64.

- BUTTFIELD, A.; FERREZ, P. W.; MILLÁN, J. D. R. Towards a Robust BCI: Error Potentials and Online Learning. *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, v. 14, n. 2, p. 167–168, 2006. Citado 2 vezes nas páginas 38 e 71.
- CAPATI, F. A.; BECHELLI, R. P.; CASTRO, M. C. F. Hybrid SSVEP/P300 BCI Keyboard - Controlled by Visual Evoked Potential. In: *Proceedings of the 9th International Joint Conference on Biomedical Engineering Systems and Technologies*. SCITEPRESS - Science and Technology Publications, 2016. v. 4, n. Biostec, p. 214–218. ISBN 978-989-758-170-0. Disponível em: <<http://www.scitepress.org/DigitalLibrary/Link.aspx?doi=10.5220/0005705202140218>>. Citado 3 vezes nas páginas 36, 38 e 68.
- CARDIONICS, I. *MultiAmp Owner's manual*. 2005. Citado 2 vezes nas páginas 42 e 132.
- Carino E., R. I.; Negrete C., J.; JOSEFINA, G. M.; VAZQUEZ, R. Decodificación de imaginación motora en la señal de electroencefalografía mediante mapas auto-organizados. *Revista del Centro de Investigación de la Universidad La Salle*, v. 12, n. 45, p. 107–125, 2016. Citado na página 43.
- CARVALHAES, C.; De Barros, J. A. The surface Laplacian technique in EEG: Theory and methods. *International Journal of Psychophysiology*, Elsevier B.V., v. 97, n. 3, p. 174–188, 2015. ISSN 18727697. Disponível em: <<http://dx.doi.org/10.1016/j.ijpsycho.2015.04.023>>. Citado 2 vezes nas páginas 45 e 47.
- CASTILLO, J. *Interface cérebro computador baseada em SSVEP e ERD para o comando de um veículo autônomo*. 109 p. Tese (Mestrado) — Universidade Federal do Espírito Santo, 2014. Citado 3 vezes nas páginas 23, 64 e 68.
- CASTILLO, J.; LONGO, B. B.; FLORIANO, A.; CAICEDO, E.; BASTOS FILHO, T. F. Optimización de una Interfaz Cerebro Computador Basada en Imaginación Motora Usando Emotiv Epoc Optimización de una Interfaz Cerebro Computador Basada en Imaginación Motora Usando Emotiv Epoc. In: *VI Jornadas de AITADIS, Rehabilitación y Tecnologías de Apoyo a la Discapacidad*. Asunción: [s.n.], 2014. p. 4. Citado na página 53.
- CHIAPPA, S.; BARBER, D. Generative Temporal ICA for Classification in Asynchronous BCI Systems. In: *Proceedings of the Second International IEEE EMBS Conference on Neural Engineering*. [S.l.: s.n.], 2005. p. 514–517. Citado 4 vezes nas páginas 51, 52, 68 e 80.
- CHIAPPA, S.; BENGIO, S. HMM and IOHMM Modeling of EEG Rhythms for Asynchronous BCI Systems. In: IDIAP. *European Symposium on Artificial Neural Networks {ESANN}*. [S.l.], 2004. Citado 2 vezes nas páginas 57 e 68.
- COETZEE, F. M. Correcting the Kullback-Leibler distance for feature selection. *Pattern Recognition Letters*, v. 26, n. 11, p. 1675–1683, aug 2005. ISSN 01678655. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0167865505000322>>. Citado 2 vezes nas páginas 55 e 56.
- COLLURA, T. F. History and evolution of electroencephalographic instruments and techniques. *Journal of clinical neurophysiology*, v. 10, n. 4, p. 476–504, 1993. ISSN

0736-0258. Disponível em: <http://journals.lww.com/clinicalneurophys/Citation-/1993/10000/History_and_Evolution_of_Electroencephalogr>. Citado na página 41.

COTRINA, A.; BENEVIDES, A.; FERREIRA, A.; Bastos Filho, T. F.; CASTILLO, J.; MENEZES, M. L.; PEREIRA, C. Towards an architecture of a hybrid BCI based on SSVEP-BCI and passive-BCI. In: *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2014. p. 1342–1345. ISBN 978-1-4244-7929-0. ISSN 1557-170X. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/25570215> <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6943847>>. Citado 3 vezes nas páginas 36, 64 e 68.

COTRINA, A.; CASTILLO, J.; BASTOS FILHO, T. F. Towards a SSVEP-BCI Based on Depth of Field. In: *6th International Brain-Computer Interface Conference 2014*. [S.l.: s.n.], 2014. Citado 2 vezes nas páginas 23 e 36.

DECETY, J. The neurophysiological basis of motor imagery. *Behavioural Brain Research*, v. 77, n. 1-2, p. 45–52, 1996. ISSN 01664328. Citado na página 74.

DELORME, A.; MAKEIG, S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics. *Journal of Neuroscience Methods*, v. 134, p. 9–21, 2004. Citado 2 vezes nas páginas 46 e 51.

DEVICES, A. *Quad-Channel Digital Isolators: ADuM1400/ ADuM1401/ ADuM1402*. [S.l.], 2007. Citado na página 132.

DIAS, N. S.; MENDES, P. M.; CORREIA, J. H. Feature Selection for Brain-Computer Interface. In: *IFMBE Proceedings*. [S.l.: s.n.], 2008. p. 318–321. Citado 2 vezes nas páginas 53 e 54.

DORNHEGE, G. *Increasing Information Transfer Rates for Brain-Computer Interfacing*. Tese (Doutorado) — University of Potsdam, 2006. Citado 5 vezes nas páginas 22, 36, 38, 45 e 68.

DORNHEGE, G.; BLANKERTZ, B.; CURIO, G. Speeding up classification of multi-channel Brain-Computer Interfaces: Common spatial patterns for slow cortical potentials. In: *First International IEEE EMBS Conference on Neural Engineering*. [S.l.: s.n.], 2003. p. 595–598. Citado 3 vezes nas páginas 42, 48 e 64.

DORNHEGE, G.; BLANKERTZ, B.; CURIO, G.; MÜLLER, K.-R. Combining Features for BCI. *Advances in Neural Inf. Proc. Systems (NIPS 02)*, v. 15, p. 1115–1122, 2002. Citado na página 38.

DORNHEGE, G.; BLANKERTZ, B.; CURIO, G.; MÜLLER, K.-R. Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms. *IEEE transactions on bio-medical engineering*, v. 51, n. 6, p. 993–1002, jun 2004. ISSN 0018-9294. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/15188870>>. Citado na página 64.

DORNHEGE, G.; BLANKERTZ, B.; CURIO, G.; MÜLLER, K.-R. Increase information transfer rates in BCI by CSP extension to multi-class. In: *Advances in Neural Information Processing Systems (NIPS03)*. [S.l.: s.n.], 2004. v. 16. Citado 2 vezes nas páginas 48 e 64.

Electrical Geodesics, I. *Electrical Geodesics, Inc.* 2017. Web page. Disponível em: <<http://egi.com/index.php>>. Citado na página 77.

Electrical Geodesics, I. *MR and MEG compatible Geodesic EEG Systems.* 2017. Disponível em: <https://egi.com/images/stories/company/documents-/GES_400_MR_brochure_Mar_>. Citado na página 43.

EPOC, E. Headset and software setup for your Emotiv EPOC neuroheadset. *SpringerReference*, p. 1–19, 2003. ISSN 0028-0836. Disponível em: <http://www.springerreference.com/index/doi/10.1007/SpringerReference_28>. Citado na página 43.

FABIANI, G. E.; MCFARLAND, D. J.; WOLPAW, J. R.; PFURTSCHELLER, G. Conversion of EEG activity into cursor movement by a brain-computer interface (BCI). *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, v. 12, n. 3, p. 331–8, sep 2004. ISSN 1534-4320. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/15473195>>. Citado 3 vezes nas páginas 37, 56 e 64.

FERRARA, F. *A Multimodal Assistive System to Control a Smart Environment.* Tese (Projeto de graduação) — Politecnico de Milano, 2015. Citado na página 64.

FERREIRA, A. *Uma Proposta de Interface Cérebro-Computador para Comando de Cadeira de Rodas.* Tese (Doutorado) — Universidade Federal do Espírito Santo, 2008. Citado 4 vezes nas páginas 23, 35, 64 e 71.

FERREZ, P. W.; MILLÁN, J. D. R. You Are Wrong!—Automatic Detection of Interaction Errors from Brain Waves. In: *Proceedings of the 19th International Joint Conference on Artificial Intelligence*. [S.l.: s.n.], 2005. p. 1413–1418. Citado 6 vezes nas páginas 38, 39, 43, 71, 107 e 108.

FLORIANO, A. *Desenvolvimento de uma Interface Cérebro-Computador Não Invasiva Baseada em Potenciais Evocados Visuais de Regime Permanente Aplicada à Comunicação Alternativa e Robô de Telepresença.* Tese (Doutorado) — Universidade Federal do Espírito Santo, 2016. Citado 3 vezes nas páginas 23, 64 e 68.

FLORIANO, A.; LONGO, B. B.; CARLOS, G. B.; Bastos Filho, T. F. Desenvolvimento de uma Interface Cérebro-Computador Baseada em Potenciais Evocados Visuais de Regime Permanente para o Comando de um Robô de Telepresença. In: *Simpósio Brasileiro de Automação Inteligente - SBAI2015*. [S.l.: s.n.], 2015. p. 6. Citado na página 64.

GALÁN, F.; OLIVA, F.; GUÀRDIA, J. Using mental tasks transitions detection to improve spontaneous mental activity classification. *Medical & biological engineering & computing*, v. 45, n. 6, p. 603–9, jun 2007. ISSN 0140-0118. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/17541665>>. Citado na página 68.

GANGULY, K.; CARMENA, J. M. Emergence of a Stable Cortical Map for Neuroprosthetic Control. *PLoS Biol*, Public Library of Science, v. 7, n. 7, p. e1000153, jul 2009. Disponível em: <<http://dx.doi.org/10.1371/journal.pbio.1000153>>. Citado na página 82.

- GLOOR, P. Neuronal Generators and the Problem of Localization in Electroencephalography: Application of Volume Conductor Theory to Electroencephalography. *Journal of Clinical Neurophysiology*, v. 2, n. 4, p. 327–354, 1985. Citado 5 vezes nas páginas 9, 30, 31, 32 e 74.
- GLUCK, M. A.; MYERS, C. E. *Gateway to Memory: An Introduction to Neural Network Modeling of the Hippocampus and Learning*. [S.l.]: MIT, 2000. Citado 3 vezes nas páginas 33, 58 e 59.
- GONZALEZ, S. L.; de Peralta Menendez, R. G.; THUT, G.; MILLÁN, J. D. R.; MORIER, P.; LANDIS, T. Very High Frequency Oscillations (VHFO) as a Predictor of Movement Intentions. *NeuroImage*, v. 23, n. 1, p. 170–179, 2006. Citado na página 40.
- GRAY, H. *Anatomy of the human body*. 20th. ed. Philadelphia: Lea & Febiger, 1918. Disponível em: <www.bartleby.com/107/>. Citado 4 vezes nas páginas 9, 10, 34 e 54.
- G.TEC. *g.Sahara Active Dry Electrode System*. 2017. Disponível em: <<http://www.gtec.at/Products/Electrodes-and-Sensors/g.SAHARA-Specs-Features>>. Citado na página 42.
- HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H.; JESÚS, O. D. *Neural Network Design*. 2nd, ebook. ed. Martin Hagan, 2014. 1012 p. ISBN 978-0971732117. Disponível em: <<http://hagan.okstate.edu/NNDesign.pdf>>. Citado 5 vezes nas páginas 59, 60, 61, 62 e 83.
- HENDEL, M.; BENYETTOU, A.; HENDEL, F. Hybrid self organizing map and probabilistic quadratic loss multi-class support vector machine for mental tasks classification. *Informatics in Medicine Unlocked*, Elsevier, v. 4, p. 1–9, 2016. ISSN 23529148. Disponível em: <<http://dx.doi.org/10.1016/j.imu.2016.09.001> <http://linkinghub.elsevier.com/retrieve/pii/S2352914816300181>>. Citado na página 56.
- HJORUNGDAL, R.-M.; SANFILIPPO, F.; OSEN, O. L.; RUTLE, A.; BYE, R. T. A Game-Based Learning Framework For Controlling Brain-Actuated Wheelchairs. In: *ECMS 2016 Proceedings edited by Thorsten Claus, Frank Herrmann, Michael Manitz, Oliver Rose*. ECMS, 2016. p. 554–563. ISBN 9780993244025. Disponível em: <<http://www.scs-europe.net/dlib/2016/2016-0554.htm>>. Citado na página 37.
- HOYA, T.; HORI, G.; BAKARDJIAN, H.; NISHIMURA, T.; SUZUKI, T.; MIYAWAKI, Y.; FUNASE, A.; CAO, J. Classification of single trail EEG Signals by a Combined Principal + Independent Analysis and Probabilistic Neural Network Approach. In: *Fourth International Symposium on Independent Component Analysis and Blind Signal Separation*. Nara, Japan: [s.n.], 2003. p. 197–202. Disponível em: <<http://www.bsp.brain.riken.go.jp/publications/2003-/ICA03HoyaHoriHovaNishimuraSuzukiMiyawakiFunaseCao.pdf>>. Citado 3 vezes nas páginas 50, 51 e 52.
- HSU, W.-Y. Application of competitive Hopfield neural network to brain-computer interface systems. *International journal of neural systems*, v. 22, n. 1, p. 51–62, feb 2012. ISSN 0129-0657. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/22262524>>. Citado na página 43.

- HUAN, N.-J.; PALANIAPPAN, R. Classification of Mental Tasks Using Fixed and Adaptive Autoregressive Models of EEG Signals. In: *Proceedings of the Second International IEEE EMBS Conference on Neural Engineering*. [S.l.: s.n.], 2005. p. 633–636. ISBN 0-7803-8709-0. Citado na página 54.
- HUIGEN, E.; PEPPER, A.; GRIMBERGEN, C. A. Investigation into the origin of the noise of surface electrodes. *Medical & Biological Engineering & Computing*, v. 40, n. 3, p. 332–338, may 2002. ISSN 0140-0118. Disponível em: <<http://link.springer.com/10.1007/BF02344216>>. Citado 2 vezes nas páginas 74 e 85.
- HYVÄRINEN, A.; OJA, E. Independent Component Analysis: Algorithms and Applications. *Neural Networks*, v. 13, n. 4-5, p. 411–430, 2000. Disponível em: <<http://www.cs.helsinki.fi/u/ahyvarin/papers/NN00new.pdf>>. Citado 2 vezes nas páginas 51 e 52.
- IFFT, P. J.; SHOKUR, S.; LI, Z.; LEBEDEV, M. a.; NICOLELIS, M. a. L. A brain-machine interface enables bimanual arm movements in monkeys. *Science translational medicine*, v. 5, n. 210, p. 210ra154, nov 2013. ISSN 1946-6242. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3967722&tool=pmcentrez&rendertype=ab>>. Citado na página 32.
- ITURRATE, I.; ANTELIS, J. M.; KÜBLER, A.; MINGUEZ, J. A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation. *IEEE Transactions on Robotics*, v. 25, n. 3, p. 614–627, jun 2009. Citado 2 vezes nas páginas 36 e 68.
- JURCAK, V.; TSUZUKI, D.; DAN, I. 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems. *NeuroImage*, v. 34, n. 4, p. 1600–1611, feb 2007. ISSN 10538119. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1053811906009724>>. Citado na página 76.
- KAYSER, J.; TENKE, C. E. Issues and considerations for using the scalp surface Laplacian in EEG/ERP research: A tutorial review. *International Journal of Psychophysiology*, Elsevier B.V., v. 97, n. 3, p. 189–209, 2015. ISSN 18727697. Disponível em: <<http://dx.doi.org/10.1016/j.ijpsycho.2015.04.012>>. Citado 3 vezes nas páginas 45, 46 e 71.
- KESHNER, M. 1/F Noise. *Proceedings of the IEEE*, v. 70, n. 3, p. 212–218, 1982. ISSN 0018-9219. Citado na página 85.
- KIM, C. S.; SUN, J.; LIU, D.; WANG, Q.; PAEK, S. G. Removal of Ocular Artifacts Using ICA and Adaptive Filter for Motor Imagery-based BCI. *IEEE/CAA Journal of Automatica Sinica*, p. 1–8, 2017. Citado 3 vezes nas páginas 51, 80 e 91.
- KOHONEN, T. *Self-Organizing Maps*. 3rd. ed. [S.l.]: Springer, 2001. 501 p. ISBN 3-540-67921-9. Citado 6 vezes nas páginas 58, 60, 61, 62, 82 e 83.
- KREPKE, R.; CURIO, G.; BLANKERTZ, B.; MÜLLER, K.-R. Berlin Brain, A Computer Interface, The HCI communication channel for discovery. *International Journal of Human-Computer Studies*, v. 65, n. 5, p. 460–477, may 2007. ISSN 10715819. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1071581906001807>>. Citado 2 vezes nas páginas 43 e 67.

- KRUSIENSKI, D. J.; SHALK, G.; MCFARLAND, D. J.; WOLPAW, J. R. Tracking of the Mu Rhythm using an Empirically Derived Matched Filter. In: *Proceedings of the Second International IEEE EMBS Conference on Neural Engineering*. [S.l.: s.n.], 2005. p. 86–89. Citado na página 64.
- KÜBLER, A.; NEUMANN, N.; KAISER, J.; KOTCHOUBEY, B.; HINTERBERGER, T.; BIRBAUMER, N. P. Brain-computer communication: Self-regulation of slow cortical potentials for verbal communication. *Archives of Physical Medicine and Rehabilitation*, v. 82, n. 11, p. 1533–1539, 2001. ISSN 00039993. Citado 2 vezes nas páginas 90 e 96.
- KULLBACK, S.; LEIBLER, R. A. On Information and Sufficiency. *The Annals of Mathematical Statistics*, v. 22, n. 1, p. 79–86, 1951. Disponível em: <<http://projecteuclid.org/euclid.aoms/1177729694>>. Citado na página 56.
- LEBEDEV, M. A.; NICOLELIS, M. A. L. Brain-machine interfaces: past, present and future. *TRENDS in neurosciences*, v. 29, n. 9, p. 536–46, sep 2006. ISSN 0166-2236. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/16859758>>. Citado na página 82.
- LEE, F.; SCHERER, R.; LEEB, R.; SCHL, A. Feature Mapping using PCA , Locally Linear Embedding and Isometric Feature Mapping for EEG-based Brain Computer Interface. In: *Digital Imaging in Media and Education, Proceedings of the 28th AAPR Workshop*. [S.l.: s.n.], 2004. Citado 2 vezes nas páginas 43 e 48.
- LEEB, R.; KEINRATH, C.; FRIEDMAN, D.; GUGER, C.; SCHERER, R.; NEUPER, C.; GARAU, M.; ANTLEY, A.; STEED, A.; SLATER, M.; PFURTSCHELLER, G. Walking by Thinking: The Brainwaves Are Crucial, Not the Muscles! *Presence: Teleoperators & Virtual Environments*, v. 15, n. 5, p. 500–514, 2006. Disponível em: <<http://www.miyuki-net.co.jp/gtec/Publications/WalkingbyThinking.pdf>>. Citado na página 66.
- LEHR JR, R. P. *Brain Functions and Map*. 2006. Disponível em: <<http://www.neuroskills.com/brain.shtml>>. Citado na página 71.
- LEMIEUX, L.; MCBRIDE, A.; HAND, J. W. Calculation of electrical potentials on the surface of a realistic head model by finite differences. *Physics in Medicine and Biology*, v. 41, p. 1079–1091, 1996. Citado na página 28.
- LIAO, L.-D.; CHEN, C.-Y.; WANG, I.-J.; CHEN, S.-F.; LI, S.-Y.; CHEN, B.-W.; CHANG, J.-Y.; LIN, C.-T. Gaming control using a wearable and wireless EEG-based brain-computer interface device with novel dry foam-based sensors. *Journal of neuroengineering and rehabilitation*, BioMed Central Ltd, v. 9, n. 1, p. 5, jan 2012. ISSN 1743-0003. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3283495&tool=pmcentrez&rendertype=ab>>. Citado na página 43.
- LIN, C.-T.; KO, L.-W.; CHANG, M.-H.; DUANN, J.-R.; CHEN, J.-Y.; SU, T.-P.; JUNG, T.-P. Review of wireless and wearable electroencephalogram systems and brain-computer interfaces—a mini-review. *Gerontology*, v. 56, n. 1, p. 112–119, 2010. ISSN 14230003. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/19641287>> <http://content.karger.com/ProdukteDB/produkte.asp?doi=10.1159/000230807>>. Citado na página 43.

LOTTE, F.; CONGEDO, M.; LOTTE, F.; CONGEDO, M.; LÉCUYER, a.; LAMARCHE, F.; LAMARCHE, F.; ARNALDI, B.; ARNALDI, B. A review of classification algorithms for EEG-based brain-computer interfaces. *Journal of neural engineering*, v. 4, n. 2, p. R1–R13, 2007. ISSN 1741-2560. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/17409472>>. Citado na página 80.

Lynx Tecnologia. *BrainNet BNT 36*. 2013. Disponível em: <<http://www.emsamed.com.br/pt-br/brainnet-bnt-36>>. Citado 2 vezes nas páginas 43 e 74.

MALMIVUO, J.; PLONSEY, R. *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. 1. ed. New York: Oxford University Press, 1995. 482 p. ISBN ISBN-10: 0195058232 ISBN-13: 978-0195058239. Citado 10 vezes nas páginas 9, 10, 26, 28, 29, 32, 35, 39, 47 e 74.

MCCANE, L. M.; HECKMAN, S. M.; MCFARLAND, D. J.; TOWNSEND, G.; MAK, J. N.; SELLERS, E. W.; ZEITLIN, D.; TENTEROMANO, L. M.; WOLPAW, J. R.; VAUGHAN, T. M. P300-based brain-computer interface (BCI) event-related potentials (ERPs): People with amyotrophic lateral sclerosis (ALS) vs. age-matched controls. *Clinical Neurophysiology*, v. 126, n. 11, p. 2124–2131, nov 2015. ISSN 13882457. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S138824571500067X>>. Citado 2 vezes nas páginas 64 e 68.

MCFARLAND, D. J. The advantages of the surface Laplacian in brain-computer interface research. *International Journal of Psychophysiology*, Elsevier B.V., v. 97, n. 3, p. 271–276, 2015. ISSN 18727697. Disponível em: <<http://dx.doi.org/10.1016/j.ijpsycho.2014.07.009>>. Citado 4 vezes nas páginas 45, 47, 64 e 79.

MCFARLAND, D. J.; SARNACKI, W. A.; VAUGHAN, T. M.; WOLPAW, J. R. Brain-computer interface (BCI) operation: signal and noise during early training sessions. *Clinical Neurophysiology*, v. 1, n. 116, p. 56–62, 2005. Citado na página 64.

MCFARLAND, D. J.; SARNACKI, W. a.; WOLPAW, J. R. Should the parameters of a BCI translation algorithm be continually adapted? *Journal of neuroscience methods*, Elsevier B.V., v. 199, n. 1, p. 103–7, jul 2011. ISSN 1872-678X. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3134307&tool=pmcentrez&rendertype=ab>>. Citado 2 vezes nas páginas 60 e 68.

MCFARLAND, D. J.; SARNACKI, W. A.; WOLPAW, J. R. Effects of training pre-movement sensorimotor rhythms on behavioral performance. *Journal of Neural Engineering*, v. 12, n. 6, p. 066021, dec 2015. ISSN 1741-2560. Disponível em: <<http://stacks.iop.org/1741-2552/12/i=6/a=066021?key=crossref.d824a7b1cfe7b036317e25c56f73a6b0>>. Citado 3 vezes nas páginas 62, 63 e 64.

MIHAJLOVIC, V.; GRUNDLEHNER, B.; VULLERS, R.; PENDERS, J. Wearable, Wireless EEG Solutions in Daily Life Applications: What are we Missing? *IEEE Journal of Biomedical and Health Informatics*, v. 19, n. 1, p. 6–21, jan 2015. ISSN 2168-2194. Disponível em: <<http://ieeexplore.ieee.org/document/6824740/>>. Citado 2 vezes nas páginas 42 e 43.

MIRANDA, R. A.; CASEBEER, W. D.; HEIN, A. M.; JUDY, J. W.; KROTKOV, E. P.; LAABS, T. L.; MANZO, J. E.; PANKRATZ, K. G.; PRATT, G. a.; SANCHEZ,

- J. C.; WEBER, D. J.; WHEELER, T. L.; LING, G. S. F. DARPA-funded efforts in the development of novel brain-computer interface technologies. *Journal of neuroscience methods*, Elsevier B.V., v. 244, p. 52–67, aug 2014. ISSN 1872-678X. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/25107852>>. Citado 2 vezes nas páginas 107 e 108.
- MORENO, J. C.; BUENO, L.; PONS, J. L. Sensors, actuators and control in Wearable Robots. In: *Proceedings of the IEEE Conference on Robotics and Automation (ICRA-08)*. Pasadena: [s.n.], 2008. Citado na página 106.
- MORENO, J. C.; BUENO, L.; PONS, J. L. Wearable Robot Technologies. In: _____. *Wearable Robots: Biomechatronic Exoskeletons*. [S.l.]: John Wiley and Sons, Inc., 2008. Wearable R, cap. 6, p. 165–200. Citado na página 107.
- MÜLLER-GERKING, J.; PFURTSCHELLER, G.; FLYVBJERG, H. Designing optimal spatial filters for single-trial EEG classification in a movement task. *Clinical Neurophysiology*, v. 110, p. 787–798, 1999. Citado 6 vezes nas páginas 43, 45, 48, 62, 63 e 81.
- MÜLLER-PUTZ, G. R.; SCHERER, R.; BRUNNER, C.; LEEB, R.; PFURTSCHELLER, G. Better than random ? A closer look on BCI results. *International Journal of Bioelectromagnetism*, v. 10, n. 1, p. 52–55, 2008. Citado 2 vezes nas páginas 90 e 96.
- MÜLLER-PUTZ, G. R.; SCHERER, R.; PFURTSCHELLER, G.; NEUPER, C. Temporal coding of brain patterns for direct limb control in humans. *Frontiers in Neuroscience*, v. 4, n. JUN, p. 1–11, 2010. ISSN 16624548. Citado 2 vezes nas páginas 63 e 66.
- MÜLLER, S. M. T. *Interface Cérebro-Computador Baseada em Potenciais Evocados Visuais em Regime Permanente para Comando de uma Cadeira de Rodas Robótica*. Tese (Doutorado) — Universidade Federal do Espírito Santo, 2012. Citado 3 vezes nas páginas 36, 64 e 68.
- NASEHI, S.; POURGHASSEM, H. Mental Task Classification Based on HMM and BPNN. In: *2013 International Conference on Communication Systems and Network Technologies*. [S.l.: s.n.], 2013. p. 210–214. ISBN 9780769549583. Citado na página 57.
- NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. *Sensors (Basel, Switzerland)*, v. 12, n. 2, p. 1211–79, jan 2012. ISSN 1424-8220. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3304110&tool=pmcentrez&rendertype=ab>>. Citado 15 vezes nas páginas 22, 36, 37, 38, 39, 42, 48, 51, 53, 54, 56, 60, 68, 80 e 81.
- NIE, J.; WARMUTH, M. K. Online PCA with Optimal Regret. *Journal of Machine Learning Research*, v. 17, n. 173, p. 1–49, 2016. Disponível em: <<http://jmlr.org/papers/v17/nie-320.html>>. Citado 2 vezes nas páginas 49 e 51.
- OBERMAIER, B. *Design and Implementation of an EEG based “Virtual Keyboard” using Hidden Markov Models*. Tese (Doutorado) — Technische Universität Graz, 2001. Citado 3 vezes nas páginas 23, 56 e 57.

OBERMAIER, B.; GUGER, C.; NEUPER, C.; PFURTSCHELLER, G. Hidden Markov models for online classification of single trial EEG data. *Pattern Recognition Letters*, v. 22, p. 1299–1309, 2001. Citado na página 56.

OBERMAIER, B.; MÜLLER, G. R.; PFURTSCHELLER, G. "Virtual Keyboard" Controlled by Spontaneous EEG Activity. *IEEE Transactions on Neural and Rehabilitation Engineering*, v. 11, n. 4, p. 422–426, 2003. Citado 4 vezes nas páginas 23, 56, 57 e 63.

OLAYA, A. F. R.; LIMA, E. R. de; BRUNETTI, F. J.; BUENO, L.; SASTOQUE, J. C. M.; ROVIRA, J. L. P. NeuroLab: A multimodal networked exoskeleton for neuromotor and biomechanical research. In: *Proceedings of International Conference On Biomedical Electronics. - BIODEVICES 2008*. Funchal: [s.n.], 2008. v. 2, p. 68–73. Citado na página 106.

OOSTENVELD, R.; PRAAMSTRA, P. The five percent electrode system for high-resolution EEG and ERP measurements. *Clinical Neurophysiology*, v. 112, n. 4, p. 713–719, 2001. ISSN 13882457. Citado na página 76.

Organización Mundial de la Salud. *Discapacidad, incluidos la prevención, el tratamiento y la rehabilitación*. 2005. Disponível em: <<http://www.un.org/esa/socdev/enable/dissres0.htm>>. Citado na página 22.

ORGANIZATION, W. H. *WHO global disability action plan 2014-2021: Better Health With for All People With Disability*. [S.l.], 2015. 32 p. Disponível em: <http://apps.who.int/iris/bitstream/10665/199544/1/9789241509619_eng.pdf?u>. Citado na página 22.

PARLIAMENT, E.; COUNCIL, O. T. *COUNCIL DIRECTIVE 93/42/EEC of 14 June 1993 concerning medical devices*. [S.l.], 2003. Disponível em: <http://www.cocir.org/uploads/documents/13-241-mdd_93_42_eec_consolidated>. Citado na página 128.

PEI, X.; ZHENG, C. Classification of Left and Right Hand Motor Imagery Tasks Based on EEG Frequency Component Selection. *The 2nd International Conference on Bioinformatics and Biomedical Engineering, 2008. ICBBE 2008.*, p. 1888–1891, 2008. Citado 2 vezes nas páginas 53 e 91.

PENFIELD, W.; RASMUSSEN, T. *The cerebral cortex of man: a clinical study of localization of function*. [S.l.]: Macmillan, 1950. 248 p. Citado 2 vezes nas páginas 9 e 35.

PEREIRA, J. R.; REIS, A. M.; MAGALHÃES, Z. Neuroanatomia Funcional: Anatomia Das Áreas Activáveis nos Usuais Paradigmas em Ressonância Magnética Funcional. *Acta Médica Portuguesa*, v. 16, p. 107–116, 2003. Citado na página 33.

PFURTSCHELLER, G.; NEUPER, C.; GUGER, C.; HARKAM, W.; RAMOSER, H.; SCHLÖGL, A.; OBERMAIER, B.; PREGENZER, M. Current trends in Graz Brain-Computer Interface (BCI) Research. *IEEE Transactions on Rehabilitation Engineering*, v. 8, n. 2, p. 216–218, 2000. Disponível em: <<http://www-cdr.stanford.edu/~jack/Pfurtscheller.p>>. Citado 6 vezes nas páginas 42, 48, 54, 55, 63 e 66.

- PINEGGER, A.; WRIESSNEGGER, S. C.; FALLER, J.; MÜLLER-PUTZ, G. R. Evaluation of Different EEG Acquisition Systems Concerning Their Suitability for Building a Brain-Computer Interface: Case Studies. *Frontiers in Neuroscience*, v. 10, sep 2016. ISSN 1662-453X. Disponível em: <<http://journal.frontiersin.org/Article/10-3389/fnins.2016.00441/abstract>>. Citado na página 63.
- PION-TONACHINI, L.; MEMBER, S.; HSU, S.-h.; MEMBER, S. Real-time EEG Source-mapping Toolbox (REST): Online ICA and Source Localization. In: *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*. [S.l.: s.n.], 2015. p. 4114–4117. Citado 3 vezes nas páginas 51, 52 e 55.
- POLIKOFF, J. B.; BUNNELL, H.; BORKOWSKI JR., W. J. Toward a P300-based computer interface. In: *Proceedings of Rehabilitation Engineering and Assistive Technology Society of North America (RESNA'95) Annual Conference*. [s.n.], 1995. p. 178–180. Disponível em: <<http://www.asel.udel.edu/speech/reports/resna95/p300.pdf>>. Citado na página 43.
- PORRO, C. A.; FRANCESCATO, M. P.; CETTOLO, V.; DIAMOND, M. E.; BARALDI, P.; ZUIANI, C.; BAZZOCCHI, M.; PRAMPERO, P. E. di. Primary motor and sensory cortex activation during motor performance and motor imagery: a functional magnetic resonance imaging study. *The Journal of neuroscience : the official journal of the Society for Neuroscience*, v. 16, n. 23, p. 7688–7698, 1996. ISSN 0270-6474. Citado na página 74.
- PROAKIS, J. G.; MANOLAKIS, D. G. *Digital signal processing – Principles, Algorithms and Applications*. Third. [S.l.]: Prentice Hall International Editions, 1996. ISBN 0-13-394338-9. Citado na página 45.
- PRUTCHI, D.; NORRIS, M. *Design and development of medical electronic instrumentation: A practical perspective of the design, construction, and testing of medical devices*. [S.l.]: Wiley-Interscience, 2005. ISBN 0-471-67623-3. Citado 3 vezes nas páginas 15, 39 e 131.
- QIN, L.; DING, L.; HE, B. Motor imagery classification by mean of source analysis for brain-computer interface applications. *Journal of Neural Engineering*, v. 1, p. 135–141, 2004. Citado 4 vezes nas páginas 51, 52, 54 e 55.
- QIN, L.; KAMOUSHI, B.; LIU, Z. M.; DING, L.; HE, B. Classification of Motor Imagery Tasks by means of Time-Frequency-Spatial Analysis for Brain-Computer Interface Applications. In: *Proceedings of the Second International IEEE EMBS Conference on Neural Engineering*. [S.l.: s.n.], 2005. p. 374–376. Citado 2 vezes nas páginas 42 e 54.
- RABINER, L. R. A tutorial on Hidden Markov Models and selected applications in speech recognition. In: *Proceedings of the IEEE*. [S.l.: s.n.], 1989. v. 77, n. 2, p. 257–286. Citado na página 57.
- RAMADAN, R. A.; VASILAKOS, A. V. Brain computer interface: control signals review. *Neurocomputing*, v. 223, n. August 2016, p. 26–44, feb 2017. ISSN 09252312. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0925231216312152>>. Citado na página 76.

- RAMOSER, H.; MÜLLER-GERKING, J.; PFURTSCHELLER, G. Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Transactions on Rehabilitation Engineering*, v. 8, p. 441–446, 2000. Citado na página 48.
- RANAWEERA, R. D.; TALAVAGE, T. M.; KRISHNAN, A. Time-frequency Features Differentiate Direction of Finger Movement in Cued and Self-paced Tasks. In: *Proceedings of the 2nd international IEEE EMBS Conference on Neural Engineering*. [S.l.: s.n.], 2005. p. 551–554. ISBN 0-7803-8710-4. Citado na página 54.
- SCHERER, R.; FALLER, J.; OPISSO, E.; COSTA, U.; STEYRL, D.; MULLER-PUTZ, G. R. Bring mental activity into action! An enhanced online co-adaptive brain-computer interface training protocol. In: *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, 2015. v. 2015-Novem, p. 2323–2326. ISBN 978-1-4244-9271-8. ISSN 1557170X. Disponível em: <<http://ieeexplore.ieee.org/document/7318858/>>. Citado 3 vezes nas páginas 63, 66 e 68.
- SCHULTZE-KRAFT, M.; BIRMAN, D.; RUSCONI, M.; ALLEFELD, C.; GÖRGEN, K.; DÄHNE, S.; BLANKERTZ, B.; HAYNES, J.-D. The point of no return in vetoing self-initiated movements. *Proceedings of the National Academy of Sciences*, v. 113, n. 4, p. 1080–1085, jan 2016. ISSN 0027-8424. Disponível em: <<http://www.pnas.org/lookup/doi/10.1073/pnas.1513569112>>. Citado 2 vezes nas páginas 64 e 67.
- SCHWARTZ, A. B.; CUI, X. T.; WEBER, D. J.; MORAN, D. W. Brain-Controlled Interfaces: Movement Restoration with Neural Prosthetics. *Neuron*, v. 52, n. 1, p. 205–220, 2006. ISSN 0896-6273. Disponível em: <<http://www.sciencedirect.com/science/article/B6WSS-4M1VCW9-J/2/5a601ecd369c295874322472bb4c708e>>. Citado 4 vezes nas páginas 9, 32, 33 e 74.
- SCHWARZ, A.; SCHERER, R.; STEYRL, D.; FALLER, J.; MULLER-PUTZ, G. R. A co-adaptive sensory motor rhythms Brain-Computer Interface based on common spatial patterns and Random Forest. In: *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, 2015. p. 1049–1052. ISBN 978-1-4244-9271-8. Disponível em: <<http://ieeexplore.ieee.org/document/7318545/>>. Citado na página 63.
- SHEDEED, H. A.; ISSA, M. F. Brain-EEG Signal Classification Based on Data Normalization for Controlling a Robotic Arm. *International Journal of Tomography and Simulation*, v. 29, n. 1, p. 72–85, 2016. Citado 2 vezes nas páginas 54 e 55.
- SHLENS, J. *A Tutorial on Principal Components Analysis*. [S.l.], 2005. Disponível em: <<http://www.sn1.salk.edu/~shlens/pub/notes/pca.p>>. Citado 2 vezes nas páginas 48 e 49.
- SILVA-SAUER, L. da; VALERO-AGUAYO, L.; VELASCO-ÁLVAREZ, F.; RON-ANGEVÍN, R.; SANCHÁ-ROS, S. Brain-computer interface: Proposal of a shaping-based training. Psychology technique in BCI system. *Revista Brasileira de Engenharia Biomédica*, v. 29, n. 2, p. 123–132, 2013. ISSN 1517-3151. Disponível em: <<http://rbeb.org.br/articles/view/id/51dea8a75ce02aaf5f000001>>. Citado 2 vezes nas páginas 43 e 68.

- SMITH, S. W. *The Scientist and Engineer's Guide to Digital Signal Processing*. [S.l.]: California Technical Publishing, 1997. Citado na página 45.
- SRIDHAR, G. V.; RAO, P. M. A Neural Network Approach for EEG Classification in BCI. *International Journal of Computer Science and Telecommunications*, v. 3, n. 10, p. 44–48, 2012. Citado na página 51.
- STEYRL, D.; KOBLER, R. J.; MÜLLER-PUTZ, G. R. On Similarities and Differences of Invasive and Non-Invasive Electrical Brain Signals in Brain-Computer Interfacing. *J. Biomedical Science and Engineering*, v. 9, n. July, p. 393–398, 2016. Citado na página 63.
- TELLO, R. G.; BISSOLI, A.; FERRARA, F.; MÜLLER, S. M. T.; FERREIRA, A.; BASTOS FILHO, T. F. Development of a Human Machine Interface for Control of Robotic Wheelchair and Smart Environment. In: *11th IFAC Symposium on Robot Control (SYROCO)*. Salvador: [s.n.], 2015. p. 136–141. Citado na página 64.
- TELLO, R. J. M. G. *A Novel Approach of Independent Brain-Computer Interface Based on SSVEP*. 128 p. Tese (Doutorado) — Universidade Federal do Espírito Santo, 2016. Citado 3 vezes nas páginas 23, 36 e 68.
- Texas Instruments. *Medical Applications Guide*. 2007. 55–58 p. Disponível em: <www.ti.com/medical>. Citado na página 135.
- Texas Instruments. *ADS1299 - Low-Noise, 8-Channel, 24-Bit Analog-to-Digital Converter for Biopotential Measurements*. 2017. Disponível em: <<http://www.ti.com/product/ADS1299>>. Citado na página 106.
- TURNIP, A.; JUNAIDI, E. Removal Artifacts from EEG Signal Using Independent Component Analysis and Principal. In: *2nd International Conference on Technology, Informatics, Management, Engineering & Environment*. [S.l.: s.n.], 2014. p. 296–302. ISBN 9781479948055. Citado 2 vezes nas páginas 49 e 51.
- UL. 2017. Disponível em: <<http://www.ul.com/global/eng/pages/aboutul/>>. Citado na página 132.
- VESANTO, J.; ALHONIEMI, E. Clustering of the Self-Organizing Map. *IEEE Transactions on Neural Networks*, v. 11, n. 3, p. 586–600, 2000. Citado na página 82.
- WANG, T.; DENG, J.; HE, B. Classifying EEG-based motor imagery tasks by means of time-frequency synthesized spatial patterns. *Clinical Neurophysiology*, v. 115, p. 2744–2753, 2004. Citado 3 vezes nas páginas 45, 63 e 81.
- WARD, L. M. Synchronous neural oscillations and cognitive processes. *Trends in Cognitive Sciences*, v. 7, n. 12, p. 553–559, 2003. Citado 3 vezes nas páginas 37, 40 e 81.
- WENTRUP, M. G.; GRAMANN, K.; WASCHER, E.; BUSS, M. EEG Source Localization for Brain-Computer-Interfaces. In: *Proceedings of the Second International IEEE EMBS Conference on Neural Engineering*. [S.l.]: IEEE EMBS, 2005. p. 128–131. Citado 3 vezes nas páginas 51, 52 e 55.
- WIDROW, B.; HOFF, M. E. Adaptive switching circuits. In: *Institute of Radio Engineers, Western Electronic Show and Convention Record*. [S.l.: s.n.], 1960. p. 96–104. Citado na página 59.

WOLPAW, J. R.; BIRBAUMER, N. Brain-computer interfaces for communication and control. In: M.E. Selzer, S. Clarke, L.G. Cohen, P. Duncan, F. G. (Ed.). *Textbook of Neural Repair and Rehabilitation; Neural Repair and Plasticity*. Cambridge: [s.n.], 2006. v. 113, n. 6, cap. 33, p. 602–614. ISBN 9780511545061. Citado na página 64.

WOLPAW, J. R.; BIRBAUMER, N.; HEETDERKS, W. J.; MCFARLAND, D. J.; PECKHAM, P. H.; SCHALK, G.; DONCHIN, E.; QUATRANO, L. A.; ROBINSON, C. J.; VAUGHAN, T. M. Brain-Computer Interface Technology: A Review of the First International Meeting. *IEEE Transaction on Rehabilitation Engineering*, v. 8, n. 2, p. 164–173, jun 2000. Disponível em: <<http://www.ocf.berkeley.edu/~anandk/neuro/BCIOverview.p>>. Citado 3 vezes nas páginas 26, 64 e 82.

WOLPAW, J. R.; BIRBAUMER, N.; MCFARLAND, D. J.; PFURTSCHELLER, G.; VAUGHAN, T. M. Brain-computer interfaces for communication and control. *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, v. 113, n. 6, p. 767–91, jun 2002. ISSN 1388-2457. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/12048038>>. Citado 2 vezes nas páginas 64 e 68.

World Health Organization. *World Report on Disability - Summary*. [S.l.], 2011. 24 p. Citado na página 22.

ZHANG, Y.; LI, S.; WANG, T.; ZHANG, Z. Neurocomputing Divergence-based feature selection for separate classes. *Neurocomputing*, Elsevier, v. 101, p. 32–42, 2013. ISSN 0925-2312. Disponível em: <<http://dx.doi.org/10.1016/j.neucom.2012.06.036>>. Citado 2 vezes nas páginas 55 e 56.

Apêndices

APÊNDICE A – Desenvolvimento de dispositivo portátil para a aquisição e processamento de sinais EEG

Este Apêndice está dedicado à descrição do dispositivo embarcado desenvolvido para a aquisição e tratamento de sinais EEG. Aqui são apresentados os desafios enfrentados na implementação deste tipo de dispositivo, além das soluções adotadas.

Na seção A.1 é mostrada uma visão geral dos desafios encontrados na implementação de um dispositivo portátil de aquisição de EEG.

Na seção A.2 são apresentadas as diretrizes de segurança elétrica necessárias para a aplicação e as soluções adotadas no dispositivo para que a aplicação siga todas as recomendações relacionadas à segurança do usuário.

A seção A.3 apresenta as características requeridas pelos dispositivos utilizados para a amplificação dos sinais EEG, as soluções buscadas para a implementação em um dispositivo portátil, e as soluções adotadas neste sistema.

A seção A.4 apresenta as características mínimas para os dispositivos de processamento do sinal EEG. Além da etapa de aquisição dos sinais analógicos, esta seção trata do dispositivo de processamento dos sinais.

A seção A.5 apresenta as características mínimas para as tarefas de armazenamento e comunicação requeridas pela aplicação. Além destas características são apresentadas as soluções encontradas para o desenvolvimento deste dispositivo.

A.1 Desafios na implementação de um dispositivo embarcado para a captura e processamento de sinais EEG

Atualmente, grande parte dos sistemas de processamento de EEG para interfaces cérebro-computador estão baseados no uso de um equipamento de nível clínico para sinais EEG associado a um computador pessoal, onde os sinais são processados. A proposta de implementar um dispositivo de aquisição e processamento de EEG embarcado portátil apresenta uma série de desafios de diferentes tipos.

Estes desafios estão relacionados principalmente com dois aspectos: segurança do usuário e aspectos informáticos. Entre os aspectos informáticos, podem ser citadas a comunicação entre o sistema embarcado e outros dispositivos, como cadeiras de rodas ou ambientes inteligentes, além da autonomia com o uso de baterias. Os aspectos relacionados à segurança do usuário serão tratados na seção A.2.

A.1.1 Aspectos da etapa de amplificação

Os desafios relacionados à etapa de amplificação do dispositivo embarcado se referem, principalmente, à supressão de ruído.

O sinal EEG possui uma amplitude muito baixa, na faixa dos micro Volts, e requerem uma etapa de amplificação com ganhos elevados. Os amplificadores devem apresentar ganhos elevados e ao mesmo tempo possuir baixo níveis de ruído interno para que o ruído característico do amplificador não contamine o sinal capturado.

Outro desafio se refere à implementação deste tipo de amplificador em um dispositivo portátil e de baixo consumo para que possa ser alimentado por baterias.

As soluções para estes desafios estão apresentadas na seção A.3.

A.1.2 Aspectos informáticos

Os desafios relacionados aos aspectos informáticos estão relacionados à capacidade de cálculo do sistema para o processamento dos sinais. Este sistema embarcado precisa processar os dados para a extração das características e classificar as mesmas para a geração de saídas classificadas. O sistema também deve possuir a capacidade de armazenar os dados adquiridos para que os mesmos possam ser analisados *off-line*.

Além da capacidade de processamento e armazenamento dos dados, o dispositivo embarcado também deve possuir um módulo de comunicação para este possa conectar-se com outros dispositivos de ajuda, como computadores pessoais, cadeiras de rodas, ambientes inteligentes, por exemplo.

A.1.3 Visão geral do sistema desenvolvido

Para a implementação do sistema, decidiu-se por uma arquitetura modular para cada uma das etapas da aquisição e processamento dos sinais. A arquitetura foi dividida em três placas com diferentes características e funções.

A primeira placa é responsável pela amplificação dos sinais e condicionamento dos mesmos para a aquisição por parte do DSP da placa de aquisição e processamento. Esta placa, por sua vez é responsável pela digitalização, processamento e classificação dos sinais amplificados. A terceira e última placa recebe os dados adquiridos pela placa de

processamento e armazena os mesmos em uma memória, podendo enviá-los a um outro sistema utilizando uma interface USB ou bluetooth.

O dispositivo desenvolvido possui a arquitetura descrita na Figura 39. Nesta figura pode-se observar as soluções implementadas e a modularidade do dispositivo. Esta implementação modular foi escolhida por permitir a substituição de qualquer um dos módulos por outros com outras funcionalidades, caso seja necessário.

A.2 Diretrizes de segurança elétrica para dispositivos de amplificação de potenciais biológicos e características elétricas do dispositivo desenvolvido

Dispositivos eletrônicos dedicados a adquirir sinais bioelétricas necessitam cumprir alguns requisitos de segurança para o usuário que vai estar conectado. Estes requisitos de segurança referem-se a níveis de tensão utilizados pela eletrônica em contato com o sujeito e à conexão do sujeito ao potencial de terra.

Os eletrodos utilizados na aquisição de sinais EEG devem ficar em contato com a pele do paciente para que a aquisição possa ser realizada, mas este contato pode apresentar risco ao sujeito se não se tomar certas precauções, as quais implicam em seguir uma série de normas que dizem respeito ao tipo de contato, à impedância do contato, à conexão com terra, etc. Estes requisitos são obrigatórios para a certificação do equipamento e seu uso, sendo que todo equipamento comercial de captura de sinais EEG devem cumprir com estes requisitos mínimos.

Esta etapa do trabalho foi dividida em duas fases distintas: uma primeira, onde implementou-se um laboratório de captura de sinais EEG, optando-se por utilizar um amplificador de uso clínico que cumpre com todas as medidas de segurança elétrica, além de um computador com placa de aquisição de dados para a captura dos sinais. Na segunda etapa do trabalho utilizou-se um amplificador clínico que dispunha de ferramentas para a aquisição e digitalização dos sinais e posterior processamento.

Parte do desenvolvimento do sistema desta Tese de Doutorado foi realizado na Espanha, seguindo as diretrizes de segurança européias. De acordo com o Conselho Europeu, o sistema desenvolvido classifica-se como um dispositivo médico. A diretiva 93/42 (PARLIAMENT; COUNCIL, 2003) classifica como dispositivo médico todos os dispositivos cuja aplicação principal seja o diagnóstico, monitoramento, tratamento ou compensação de alguma lesão ou deficiência, que não alcança seu objetivo principal através da utilização de meios farmacológicos, imunológicos ou metabólicos. O sistema aqui desenvolvido se propõe a capturar dados (monitoramento) e apresentar uma interface para o sujeito. Neste caso, o desenvolvimento deste sistema deve seguir as recomendações da diretiva europeia

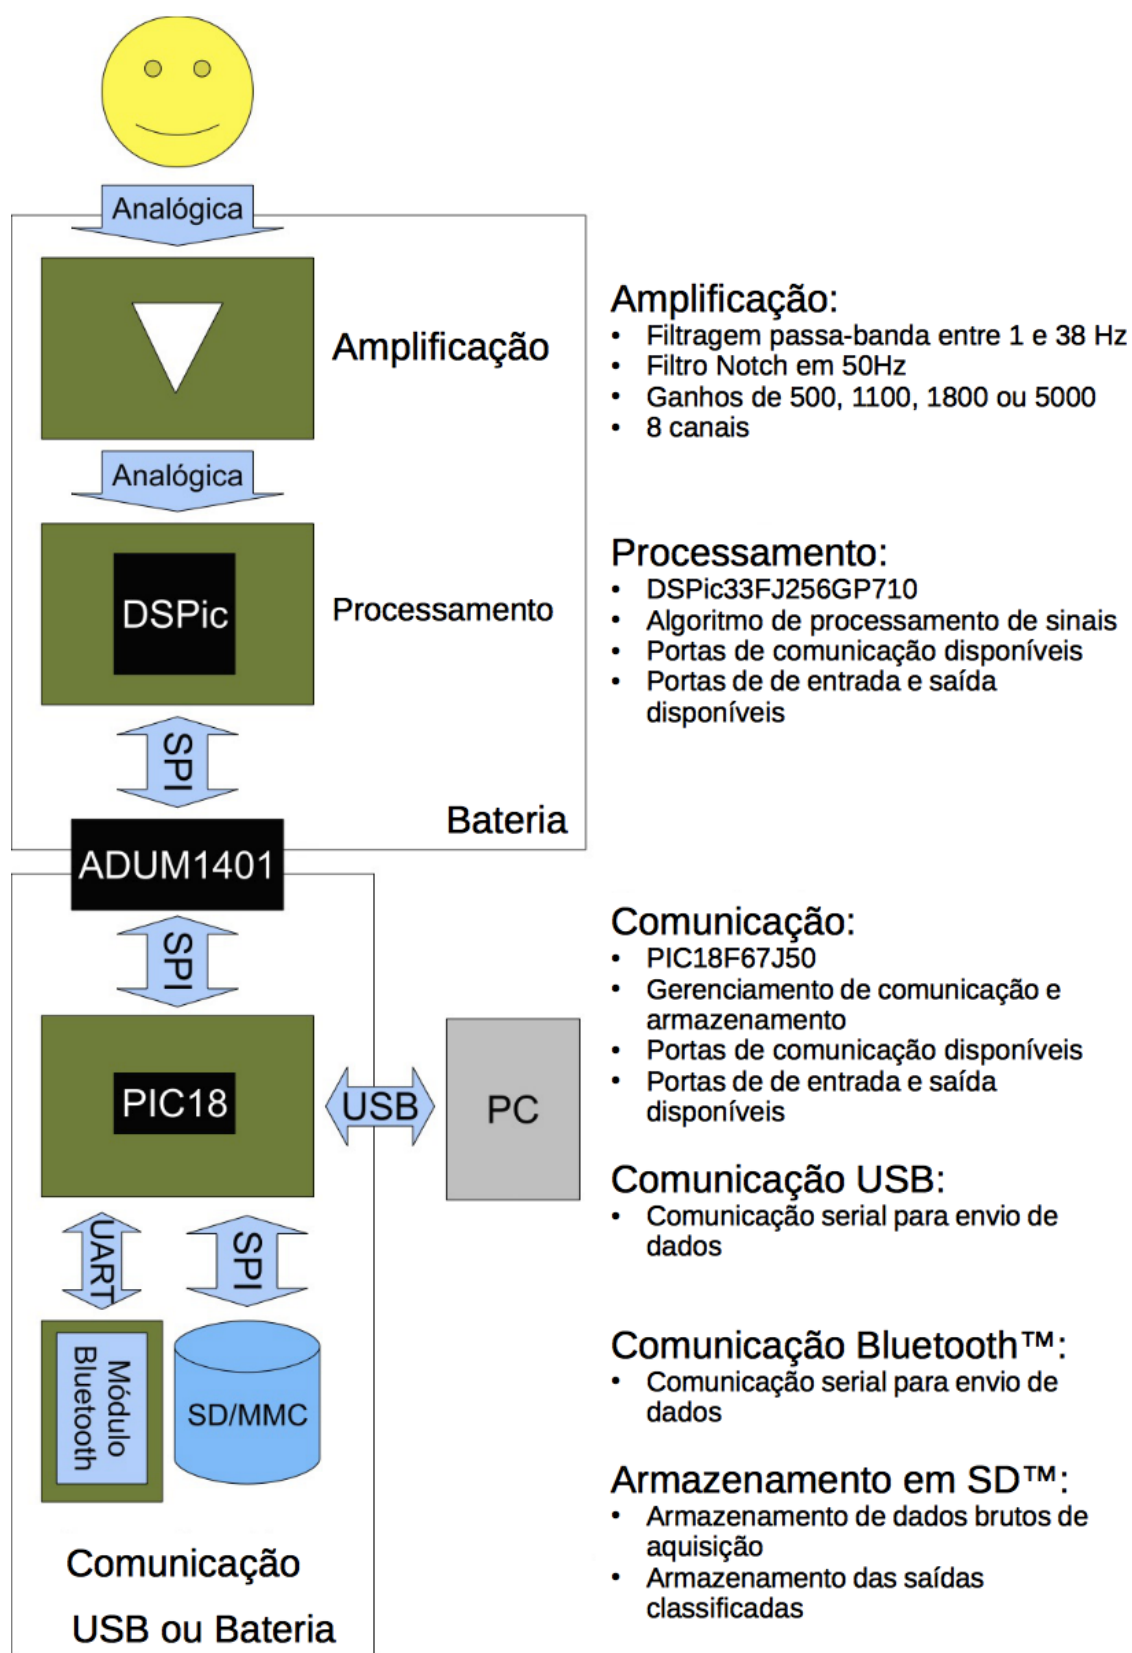


Figura 39 – Esquema das placas do sistema de aquisição, processamento e comunicação utilizadas pelo sistema. Também se observa na figura a distribuição das fontes de alimentação utilizadas por cada uma das etapas.

para o desenvolvimento de dispositivos médicos. O Anexo IX desta diretriz apresenta uma classificação dos dispositivos médicos, segundo distintos aspectos do seu uso.

Segundo os parâmetros da diretriz, estes dispositivos devem ser caracterizado como:

- De curta aplicação, segundo a duração. A utilização do dispositivo deve ser contínua, porém, por períodos não superiores a 30 dias. Espera-se que o dispositivo seja desconectado do usuário algumas vezes por semana, para recarga das baterias, por exemplo, ou para a higiene do usuário;
- Não invasivo, segundo a invasividade. O dispositivo não é inserido no corpo do sujeito, e sua aplicação é sobre a pele;
- Dispositivo médico ativo, porque utiliza uma fonte de alimentação externa, neste caso, como um conjunto de baterias, por exemplo;
- Dispositivo terapêutico ativo, porque está projetado para oferecer uma ajuda técnica a uma deficiência do sujeito.

Seguindo as regras de classificação dos dispositivos não-invasivos da diretriz, o sistema desenvolvido se encaixa nos dispositivos de classe I e, segundo a classificação dos dispositivos ativos, o mesmo também se encaixa na classe I.

Os dispositivos também podem ser classificados de acordo com a conexão do sujeito à terra, sendo classificados como flutuantes (tipo F), se o dispositivo não possui uma conexão à terra, e como dispositivos não-flutuantes (tipo B), se o dispositivo possui uma conexão do usuário à terra através do dispositivo.

Os sistemas utilizados neste trabalho são do tipo F porque ambos os amplificadores clínicos utilizados possuem entradas isoladas e sem conexão à terra.

Os equipamentos podem ser classificados de acordo com os níveis de segurança elétrica para os usuários dos equipamentos de acordo com o apresentado na Tabela 9.

As classes apresentadas na Tabela 9 é válida para dispositivos em geral, não apenas para equipamentos de aplicação clínica. A aplicação clínica possui outra classificação que depende do tipo de contato que o dispositivo faz com a pele e com os fluidos para a determinação do nível de segurança necessária. Se este contato se realiza somente sobre a pele intacta e seca, as restrições são muito menores que no caso dos dispositivos que entram em contato com a pele através de um contato úmido ou que se conectam em regiões onde podem haver feridas ou rompimentos da pele. Os dispositivos que entram em contato com o sangue, como os implantes são os que possuem as maiores restrições pelo contato com tecidos que apresentam alta condutividade, já que a circulação de corrente nestes tecidos pode causar danos graves ao paciente ou mesmo a sua morte.

Tabela 9 – Classificação dos dispositivos de acordo com a proteção do usuário contra riscos de choque elétrico. Os dispositivos de classe I são os que requerem os níveis mais baixos de isolamento. Os dispositivos de classe III apresentam isolamento reforçado e utilizam tensões de alimentação reduzida.

Classe	Descrição
Classe I	Equipamentos nos quais a proteção dos usuários está baseada no isolamento da entrada de energia através de transformadores e possuem a carcaça do equipamento conectada ao potencial de terra da instalação elétrica.
Classe II	Equipamentos nos quais a proteção do usuário está baseada na utilização de um isolamento duplo, ou em um isolamento simples, porém reforçado.
Classe III	Equipamentos alimentados por tensões baixas. Esta classe de dispositivos opera com níveis de tensão de alimentação inferiores a $25V_{ac}$ ou $60V_{dc}$. As tensões no equipamento não podem superar estes valores em nenhum ponto do circuito, e a referência do circuito deve ser isolada da rede elétrica através de um transformador isolador.

Para os equipamentos clínicos, utiliza-se a classificação apresentada na tabela 10.

Tabela 10 – Classificação de segurança dos dispositivos de aplicação clínica (PRUTCHI; NORRIS, 2005). Segundo esta classificação, o dispositivo aqui descrito deve ser caracterizado com “BF”.

Tipo	Descrição
B	Partes em contato com o sujeito se conectam diretamente à terra
BF	Partes em contacto com o sujeito estão isoladas da terra, de maneira que os níveis de corrente sejam seguros para os sujeitos conectados ao dispositivo. A letra “F” se refere ao fato de que a entrada é flutuante.
CF	Similar a “BF”, porém se aplica especificamente a dispositivos que se conectam diretamente aos tecidos do coração.

O dispositivo desenvolvido se conecta à pele intacta através de um contato úmido e também se conecta a outros dispositivos. Por este motivo, este dispositivo deve ser enquadrado na classe II e possuir um isolamento duplo ou reforçado para o contato com a terra. De acordo com a classificação de dispositivos clínicos, este aparelho deve pertencer à classe “BF” e apresentar uma entrada isolada das possíveis fontes de alimentação conectadas à rede elétrica.

O dispositivo desenvolvido é alimentado por baterias e possui características dos equipamentos de classe III, como os baixos níveis de tensão em todos os pontos do circuito,

devido à sua alimentação exclusiva através de baterias. As placas de amplificação e a placa de processamento são alimentados exclusivamente por baterias e está isolado da placa de comunicação por meio de um circuito isolador capacitivo, ADUM1401, certificado pela UL¹, CSA², VDE³ e pela TÜV⁴ como de isolamento reforçado (DEVICES, 2007). A placa de comunicação pode estar conectada a um computador pessoal ou a um outro dispositivo que pode estar conectado a uma fonte de alimentação conectada à rede elétrica. Como esta placa não está em contato direto com o usuário, ela não apresenta riscos ao usuário do sistema, devido ao isolamento do ADUM1401.

O protótipo foi desenvolvido seguindo estas diretrizes para que possa obter autorização para a utilização em um ambiente clínico para a realização dos experimentos necessários.

A.3 Amplificação e filtragem dos sinais

A etapa de amplificação está composta por um conjunto de eletrodos aplicados sobre a pele do usuário do dispositivo e por uma placa responsável pela amplificação e filtragem dos sinais presentes nos eletrodos. Estes sinais podem ser capturados para diferentes finalidades, como a monitorização terapêutica, ou para o controle de dispositivos. Os eletrodos utilizados são eletrodos padrão reutilizáveis e não serão discutidos neste trabalho.

De acordo com o que foi apresentado anteriormente, a placa desenvolvida para a amplificação será alimentada exclusivamente por baterias e sem conexão à terra, para garantir a segurança do usuário.

O módulo de amplificação deve ser capaz de amplificar os sinais presentes no couro cabeludo do sujeito e filtrá-los para a eliminação das faixas de frequência indesejadas, e do ruído induzido pela rede elétrica.

As características do amplificador embarcado foram estimadas a partir do equipamento clínico utilizado nos experimentos com um PC (CARDIONICS, 2005).

A Tabela 11 apresenta os valores de ganho e sensibilidade para ambos: o baseado no equipamento Multiamp e o dispositivo construído.

Observa-se na Tabela 11 que os valores de ganho equivalentes do dispositivo embarcado são mais baixos devido a que a excursão de saída dos dois sistemas são diferentes, já que o MultiAmp possui uma excursão de 20V pico a pico, enquanto que o dispositivo

¹ Underwriters' Laboratories – Órgão de validação e certificação particular fundado em 1894. (UL, 2017)

² Canadian Standard Association – Órgão de validação e certificação canadense.

³ Verband der Elektrotechnik, Elektronik und Informationstechnik – Órgão de certificação alemão.

⁴ Technischer Überwachungsverein – Órgão de certificação alemão.

Tabela 11 – Valores de sensibilidade de entrada para os ganhos do MultiAmp e do dispositivo desenvolvido. Considera-se para o cálculo da sensibilidade a placa de aquisição utilizada no laboratório (NI PCI-6024E, 12 bits) e o conversor A/D disponível no DSPic utilizado no dispositivo, também de 12 bits, e a excursão máxima da saída de cada um dos amplificadores utilizados.

Ganho MultiAmp [V/V]	Sensibilidade de entrada [μ V/bit]	Ganho dispositivo [V/V]	Sensibilidade de entrada [μ V/bit]
1000	2.44	-	-
2000	1.22	-	-
5000	0,488	500	0,488
10000	0,244	1100	0,222
20000	0,122	1800	0,136
50000	0,048	5000	0,048

embarcado possui uma excursão de 3V pico a pico. A seleção de ganhos no sistema embarcado é realizada através de um conjunto de conectores do tipo “jumper” nas placas dos módulos amplificadores individuais. Esta estratégia de seleção foi escolhida para diminuir o tamanho das conexões dentro do sistema, tendo o inconveniente de necessitar a abertura do invólucro do dispositivo para a seleção de ganhos.

O dispositivo deve ser ajustado ao sujeito na etapa de ajuste e, nesta etapa, além dos coeficientes do sistema de classificação, os ganhos da etapa analógica devem ser programados e, uma vez ajustados ao sujeito, o dispositivo não deve ser modificado, a não ser que o sistema apresente altos níveis de erro.

O dispositivo portátil possui 8 canais de amplificação que se mostraram suficientes para a utilização com os algoritmos de classificação desenvolvidos.

Os amplificadores do dispositivo embarcado foram desenvolvidos com uma banda passante entre 1 e 38Hz, com um filtro “notch” adicional sintonizado para a frequência de 50Hz para atenuar o ruído induzido pela rede elétrica⁵. Esta largura de banda é a mesma apresentada na seção 2.1 e utilizada para o diagnóstico de EEG.

A Figura 40 apresenta um diagrama de blocos da etapa de amplificação analógica utilizada no dispositivo. Observa-se a modularidade do projeto com a utilização de placas de amplificação individuais com 2 canais cada. Esta solução foi implementada para facilitar o desenvolvimento e a manutenção dos amplificadores do dispositivo. No caso de falhas, pode-se substituir apenas a placa defeituosa. Esta modularidade permite também a construção de dispositivos de amplificação com mais canais sem custos adicionais de projeto de novas placas de amplificação.

A placa base é responsável pelas conexões de entrada e de saída das placas de

⁵ Este sistema foi desenvolvido na Espanha, onde a rede elétrica possui frequência de 50Hz (da Espanha), porém os filtros foram projetados de tal forma que a atenuação a 60Hz é a mesma do filtro “notch” em 60Hz para utilização no Brasil

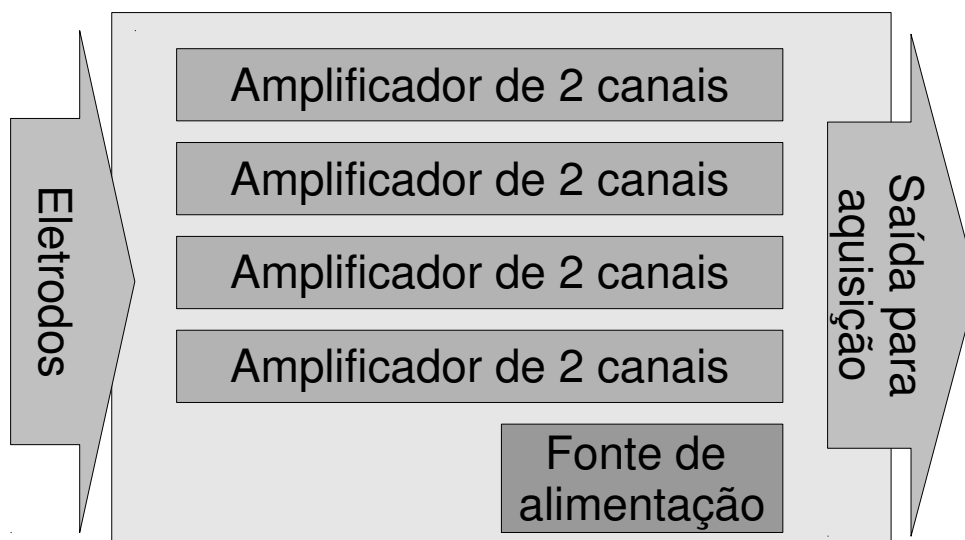


Figura 40 – Diagrama de blocos da placa de amplificação. Este diagrama representa os blocos funcionais da placa de amplificação. As placas individuais de amplificação conectam-se às entradas e saídas através de uma placa base que também provê alimentação a estas.

amplificação, além de suportar o regulador de tensão e as conexões necessárias. O diagrama esquemático desta placa está representado na Figura 41, onde podem ser vistas as conexões de entrada, saída e da fonte de alimentação. Por estar em contato com o usuário, esta placa somente deve ser alimentada por baterias.

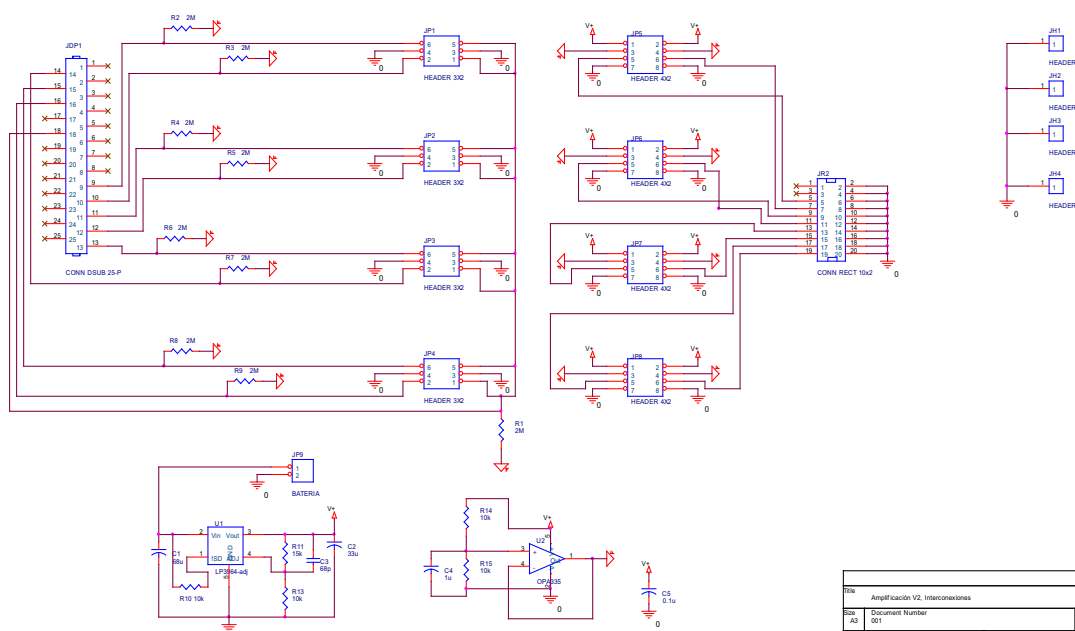


Figura 41 – Diagrama esquemático da placa base do sistema de amplificação. Pode-se observar as conexões dos 8 eletrodos de entrada, as conexões de saída e a fonte de alimentação regulada que compõem o circuito desta placa.

A Figura 42 apresenta uma foto da placa base da etapa de amplificação, onde podem-se ver os detalhes da implementação física do sistema.




Figura 42 – Fotografia da placa base do sistema de amplificação onde se pode observar a fonte de alimentação, e os conectores de entrada e saída das placas de amplificação de 2 canais.

Observa-se a utilização de quase todos os componentes de montagem superficial, o que permite otimizar o espaço na placa, liberando espaço para as placas de amplificação. Com as mesmas dimensões da placa base atual, é possível implementar um amplificador de até 12 canais, com pequenas mudanças na localização dos componentes da fonte de alimentação e com a utilização de novos conectores de entrada e saída.

As placas de amplificação foram construídas utilizando-se componentes de precisão superior (1% para os resistores e 10% para os capacitores) para que os ganhos e as respostas de frequência dos diferentes canais sejam mais uniformes entre os canais. Os amplificadores operacionais utilizados nas placas de amplificação são dispositivos de baixa tensão de alimentação, baixo consumo de energia e baixo nível de ruído, desenvolvidos para a aplicação em dispositivos médicos portáteis, como amplificadores para sinais EEG/ECG portáteis, oxímetros, etc (Texas Instruments, 2007).

A Figura 43 representa o diagrama esquemático da placa de amplificação de dois canais. Pode-se observar a utilização do amplificador de instrumentação INA2332 na entrada da placa. Este amplificador possui várias características muito interessantes para a interface com os eletrodos, como impedância de entrada elevada ($10^{13} \Omega$), rejeição de modo comum de 73 dB, além de uma corrente de polarização das entradas de $0,5 \text{ pA}$. Os amplificadores da placa são da família OPA2335 que possuem correção de ruído de entrada com ajuste a uma taxa de 10 kHz.

Na Figura 44 pode-se observar as fotografias da placa de amplificação de 2 canais utilizadas no dispositivo. Pode-se observar também a utilização de componentes de montagem superficial (SMD) para a otimização do espaço. A utilização de componentes SMD de dimensões relativamente grandes se deve ao processo manual de soldagem que limita as dimensões mínimas dos componentes utilizados. Apesar desta limitação, as placas foram implementadas em pequenas dimensões.

Na Figura 45 pode-se observar o circuito de amplificação completo com as 4 placas

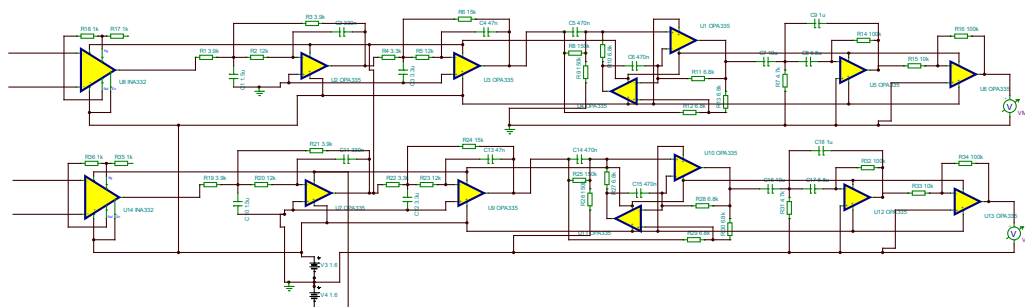


Figura 43 – Diagrama esquemático da placa de amplificação de 2 canais utilizada no dispositivo. O circuito possui uma entrada diferencial seguida por um conjunto de filtros passa-baixas, passa-altas, ambos com ganhos não-unitários, um filtro “notch” para atenuar os efeitos do ruído induzido pela rede, e um amplificador para ajuste de ganho do dispositivo.




Figura 44 – Fotografia da placa de amplificação de 2 canais utilizada no dispositivo portátil.

de amplificação de 2 canais montadas na placa base. Pode-se observar que apesar dos grandes conectores utilizados para a conexão das placas, pode-se considerar este como um dispositivo compacto.

A.4 Aquisição e processamento

Para realizar a aquisição dos sinais, foi desenvolvida uma placa dedicada à aquisição e processamento dos dados. Esta placa foi projetada tomando por base o processador digital de sinais (DSP) modelo dsPIC33FJ256GP710 operando a 40 MHz. Este DSP possui diferentes periféricos integrados, como o conversor analógico/digital de 12 bits, diferentes opções de interfaces de comunicação, como SPI, I²C e UART, além de uma quantidade de memória suficiente para a implementação dos algoritmos desenvolvidos.




Figura 45 – Fotografia das placas de amplificação montadas na placa base. Nesta foto pode-se observar o encaixe das placas individuais à placa base e os conectores para ajuste de ganho das placas de amplificação.

Para chegar a um valor mínimo de velocidade do processador, foram utilizadas as estimações preliminares de custo computacional dos algoritmos utilizados no sistema de processamento dos dados. A estimativa de custo computacional está descrita na seção A.4.1.

Na Figura 46 está representado o diagrama esquemático da placa de processamento de las sinais.

Esta placa possui um diagrama esquemático relativamente simples e com poucos componentes, pois sua função é suportar o DSP, conectar o mesmo à placa de amplificação e preparar a conexão isolada com a placa de comunicação. Com o fim de isolar a conexão entre as duas placas, foi utilizado um acoplador capacitivo ADUM1401, já citado na seção A.2, que provê a comunicação com um isolamento duplo entre entrada e saída.

Nesta placa estão disponíveis todas as portas de comunicação serial que não foram utilizadas no dispositivo, como portas de expansão. Estas portas de comunicação também podem ser utilizadas, caso seja necessário realizar a conexão entre o dispositivo desenvolvido e outros sistemas de aquisição em contato com o sujeito.

Na Figura 47 pode-se observar o primeiro protótipo da placa de processamento dos sinais. Devido a alguns erros encontrados na confecção da mesma, algumas conexões foram corrigidas utilizando-se cabos soldados aos componentes. As falhas foram corrigidas

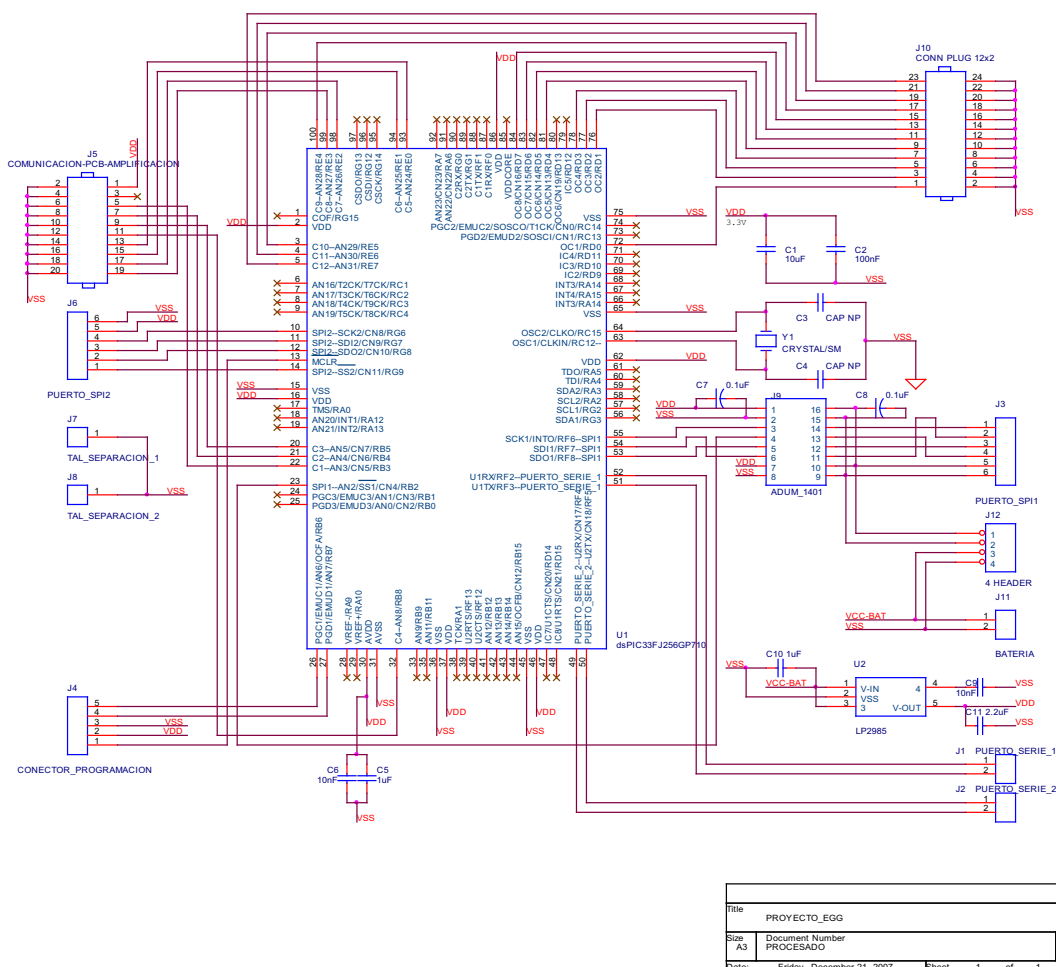


Figura 46 – Diagrama esquemático da placa de processamento dos sinais EEG. Esta placa está baseada no dsPIC33FJ256GP710 do fabricante Microchip.

no projeto, e caso outras placas sejam confeccionadas, os erros observados já estarão corrigidos.

Esta placa possui seu próprio regulador de tensão, que a torna independente da placa de amplificação. Desta maneira, pode-se utilizar mais de uma placa, caso se deseje realizar um processamento paralelo, utilizando mais de uma placa ou utilizar a mesma placa para processar sinais de outros sensores.

A.4.1 Estimação do custo computacional do módulo de processamento de sinais EEG

Para realizar uma estimativa do custo computacional do dispositivo, os dados da implementação utilizando o computador foram reunidos e a tradução para a linguagem C dos procedimentos foi realizada utilizando as ferramentas das bibliotecas de tratamento de sinais do próprio fabricante que fornece os tempos de execução em ciclos de máquina para cada uma das funções.




Figura 47 – Fotografia da placa de processamento dos sinais EEG.

O algoritmo de extração de características utiliza as componentes de frequência geradas pelo cálculo da transformada de Fourier dos sinais capturados.

A estimação do custo computacional foi dividida na estimação do custo para a aquisição, custo para o processamento e classificação, e custo para o envio dos dados à placa de armazenamento.

A aquisição dos sinais foi implementada utilizando as funções do dsPIC utilizadas para a realização da aquisição utilizando o recurso de acesso direto à memória (*Direct Memory Access* – DMA) associado ao conversor analógico digital para a aquisição de dados sem intervenção do processador. Este recurso permite que um conjunto de dados de um determinado tamanho seja digitalizado e armazenado em memória sem intervenção do processador, após esta aquisição, o controlador de DMA interrompe o processador para que os dados sejam copiados para outro espaço de memória onde os mesmos podem ser tratados.

Esta movimentação de dados consome dois ciclos de execução para cada valor copiado da memória DMA para a memória de trabalho. O tempo para a realização desta tarefa, neste caso, é de: $64 \times 2 \text{ ciclos} = 128$, ciclos que correspondem a $3,2 \mu s$. Quando computamos os ciclos necessários para os saltos relacionados ao atendimento da interrupção associada à DMA, este número salta para 132 ciclos.

O processamento dos sinais está dividido em duas etapas diferentes. A primeira etapa é a geração das características de frequência utilizando a transformada de Fourier dos dados adquiridos e seleção de alguns componentes. Para esta etapa, é necessário a realização das seguintes operações:

1. Cópia dos dados da memória de armazenamento à memória de trabalho da função para o cálculo da transformada de Fourier;
2. Cálculo da Transformada de Fourier dos dados no vetor de trabalho;
3. Organização dos dados na memória na ordem de bit reverso
4. Cálculo dos valores absolutos das componentes;
5. Seleção das características de interesse.

As ações listadas acima utilizam funções implementadas nas bibliotecas disponibilizadas pelo fabricante (MicrochipTM). Considerando-se o vetor de trabalho de 128 posições, o número de ciclos de máquina necessário para a execução das tarefas listadas acima, considerando-se o uso de 20 características por canal é de $268 + 8485 + 945 + 404 + 40 = 10142$ ciclos, para cada um dos canais. O que totaliza $253,55\mu s$ por canal.

A classificação se realiza utilizando-se uma rede neural previamente treinada e carregada no DSP. A arquitetura da rede neural utilizada é uma rede SOM ou rede de Kohonen. O mapa é gerado *off-line* e este mapa é carregado no sistema embarcado. O funcionamento do mapa está baseado no cálculo do produto interno entre o vetor de características do sinal adquirido e os vetores que compõem os neurônios da rede SOM. Utilizando-se uma rede de 20 vetores com 20 características por canal, totalizando 160 características por neurônio, tem-se um tempo de execução de $20 \times 497 = 9940$ ciclos.

O consumo total de ciclos do processamento é de 20082 ciclos, para o processamento e classificação dos sinais, aproximadamente.

O envio dos dados para a placa de armazenamento utiliza as capacidades de acesso direto à memória para envio de dados através do dispositivo SPI do dsPIC. Para tal, os dados devem ser copiados para uma outra região de memória, e posteriormente, o dispositivo SPI deve ser iniciado e a transmissão cessa quando o contador da DMA chega ao final do vetor. Este procedimento é realizado em aproximadamente 175 ciclos.

Todo o procedimento de processamento das características, identificação das tarefas e envio dos dados para a placa de comunicação consome aproximadamente $506,5\mu s$. A frequência de amostragem dos sinais é de 128 Hz por canal, o que dá um período de amostragem de $7,8ms$. A interrupção da DMA é disparada a cada 8 amostras para cada canal, o que significa que um novo conjunto de dados está disponível para processamento a cada $0,0625s$. Desta forma as saídas são geradas a uma taxa de 16 Hz, o que permite fazer uma reclassificação utilizando 8 amostras e ainda assim gerar uma saída a cada $0,5s$.

A.5 Armazenamento e envio de dados

Uma das etapas mais importantes deste desenvolvimento foi a implementação da comunicação do dispositivo de processamento a outros dispositivos. Para isto foi desenvolvida uma placa com estas funcionalidades. Esta placa é responsável pelo armazenamento dos dados adquiridos para posterior análise e pelo envio dos dados a um computador ou outro dispositivo através de uma conexão serial, Bluetooth ou USB.

Esta placa, apresentada na Figura 48 é controlada por um microcontrolador PIC18F67J50. Este microcontrolador possui conectividade USB, além de 2 portas SPI que foram utilizados para la conexão entre las placas de processamento e comunicação, e para o acesso ao cartão de memória SDTM utilizado para armazenar os dados dos experimentos. O microcontrolador também possui 2 portas seriais, das quais uma é utilizada para o controle de um módulo de comunicação Bluetooth®. A segunda porta serial está disponível na placa para futuras ampliações.




Figura 48 – Fotografia do protótipo da placa de comunicação. A placa possui conectividade USB e Bluetooth®, e a capacidade de armazenar dados em uma placa de memória Secure DigitalTM (SDTM)

Esta placa também precisou ser corrigida com fios, devido a erros de manufatura. As correções feitas ao protótipo com fios foram agregadas ao diagrama esquemático e serão corrigidos quando da manufatura de novos protótipos.

O diagrama esquemático da placa está representado na Figura 49, o qual é re-

lativamente simples, tal como a placa de processamento. A função desta placa é a de prover ao sistema as funcionalidades de armazenamento dos dados recebidos, e também prover a comunicação do sistema de aquisição e processamento a outros dispositivos, como computadores pessoais, cadeiras de rodas, etc.

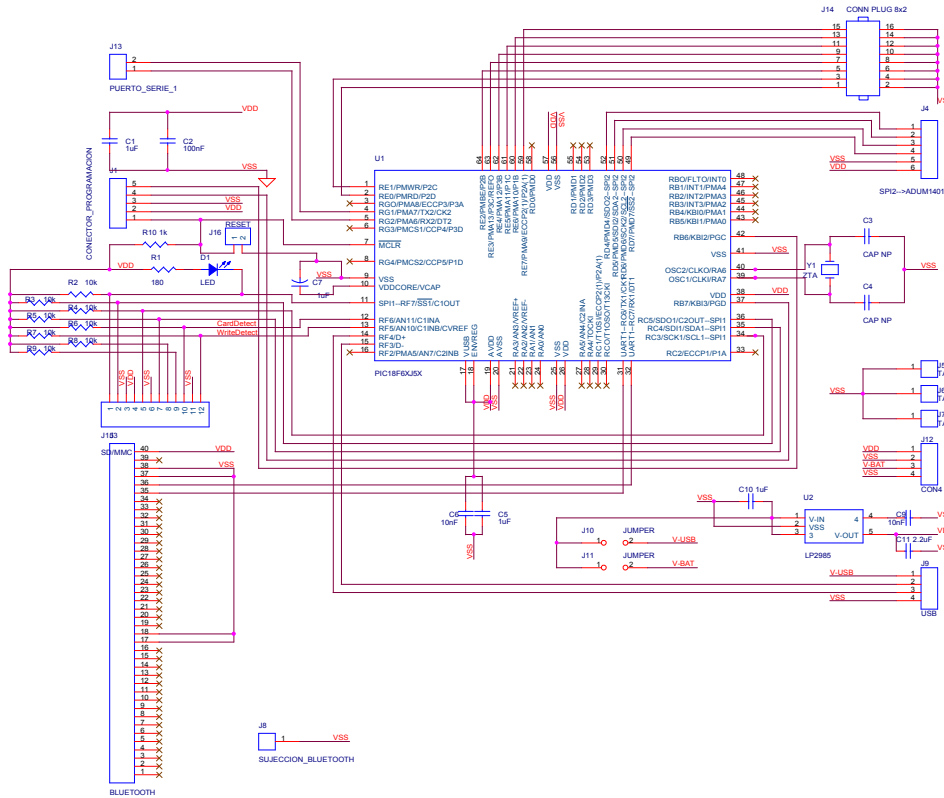


Figura 49 – Diagrama esquemático da placa de comunicação.

A placa de comunicação possui a capacidade de alimentar-se através de uma bateria adicional ao sistema embarcado, através da mesma bateria das outras placas, ou através da conexão USB. Entretanto, estes tipos de alimentação são incompatíveis entre si e a seleção de um deles não é realizada de forma automática. Para selecionar o tipo de alimentação entre bateria e USB, é necessário trocar um “jumper” na placa. O dispositivo também não possui a capacidade de carregar suas baterias através de uma conexão USB. As baterias devem ser retiradas para que possam ser recarregadas. Uma situação que deve ser evitada é a que a placa é alimentada pela mesma bateria das outras duas placas, e esta placa é conectada a um computador pessoal através da porta USB. Esta situação pode gerar riscos de choque elétrico ao usuário.

As placas de processamento e comunicação se conectam, como se pode visualizar na Figura 50, através de conectores entre as duas placas. Esta conexão entre as placas realiza a conexão de dados entre as placas e também fornece alimentação para um dos lados do isolador ADuM1401 utilizado no sistema para transmitir os sinais de comunicação entre as placas do sistema.




Figura 50 – Fotografia das placas de processamento e comunicação conectadas. Este conjunto realiza a aquisição, processamento, armazenamento e envio dos sinais EEG.

O microcontrolador utilizado na placa de comunicação tem uma capacidade de processamento de 12 MIPS⁶ partindo de um relógio de 48 MHz criado internamente através de um circuito PLL. O dispositivo recebe os dados da placa de processamento e enviá-los dados ao dispositivo em questão.

O módulo bluetooth e a conexão USB utilizam o protocolo de comunicação serial, realizando a emulação de portas seriais de comunicação com o PC para o envio de dados do sistema ao computador.

A.6 Resumo e conclusões

Neste Apêndice foi apresentada a arquitetura básica do dispositivo embarcado desenvolvido para a implementação de uma interface cérebro-computador (ICC). Foram apresentadas as características dos dispositivos físicos utilizados nas placas para que as funcionalidades necessárias à aplicação pudessem ser executadas.

As características de segurança elétrica para dispositivos eletrônicos em contato com o corpo humano foram apresentadas em detalhe neste Apêndice. Foram apresentadas as características do dispositivo desenvolvido, ressaltando as propriedades do mesmo com relação aos requisitos de segurança apresentados.

⁶ *Million Instructions per Second* – Milhões de Instruções por Segundo.

As placas desenvolvidas neste trabalho também são apresentadas, juntamente com os diagramas esquemáticos das mesmas.

As funções básicas das placas foram testadas individualmente e apresentaram resultados satisfatórios. A integração das funções individuais e a implementação final são propostas de trabalhos futuros.